ANALYSE BIOELEKTRISCHER HIRNAKTIVITÄT

Dissertation

zur Erlangung des Doktorgrades
der Mathematisch-Naturwissenschaftlichen Fakultät
der Georg-August-Universität zu Göttingen

vorgelegt von

Günter Bodenstein
aus Lengerich

Göttingen 1976

ANALYSE BIOELEKTRISCHER HIRNAKTIVITÄT

Dissertation

zur Erlangung des Doktorgrades

der Mathematisch-Naturwissenschaftlichen Fakultät

der Georg-August-Universität zu Göttingen

vorgelegt von

Günter Bodenstein

aus Lengerich

Göttingen 1976

D 7

UNIV.
LEIDEN
BIBL.

Referent: Prof. M.R. Schroeder

Korreferent: Prof. R. Pottel

Tag der mündlichen Prüfung: 4. 11. 1976

Inhaltsverzeichnis

	Seite
1. Einleitung	1
TEIL A: SPONTANE PHÄNOMENE DAS KLINISCHE ELEKTROENZEPHALOGRAMM	3
2. Mustererkennung und Merkmalsgewinnung	3
3. Ein phänomenologisches Modell	9
4. Lineare Prädiktion und spektrale Approximation	12
5. Spektrale Änderung und Segmentierung	23
6. Erkennung und Elimination von Transienten	29
7. Extraktion der Merkmale	34
8. Wahl der Parameter	39
9. Qualitätskontrolle	47
10. Erweiterung auf mehrere Kanäle	56
11. Perspektiven	59
TEIL B: EVOZIERTE PHÄNOMENE MODULATIONSTRANSFER IM AKUSTISCHEN SYSTEM	65
12. Stimuli und Observable	65
13. Die Wiener-Volterra-Entwicklung	71
14. Akustisches System und Modulationstransfer	80
15. Das Experiment und die Bestimmung der Kerne	86
16. Interpretation der Kerne	94
17. Instationäres Verhalten	101
18. Ein strukturelles Modell	107
Literaturverzeichnis	111

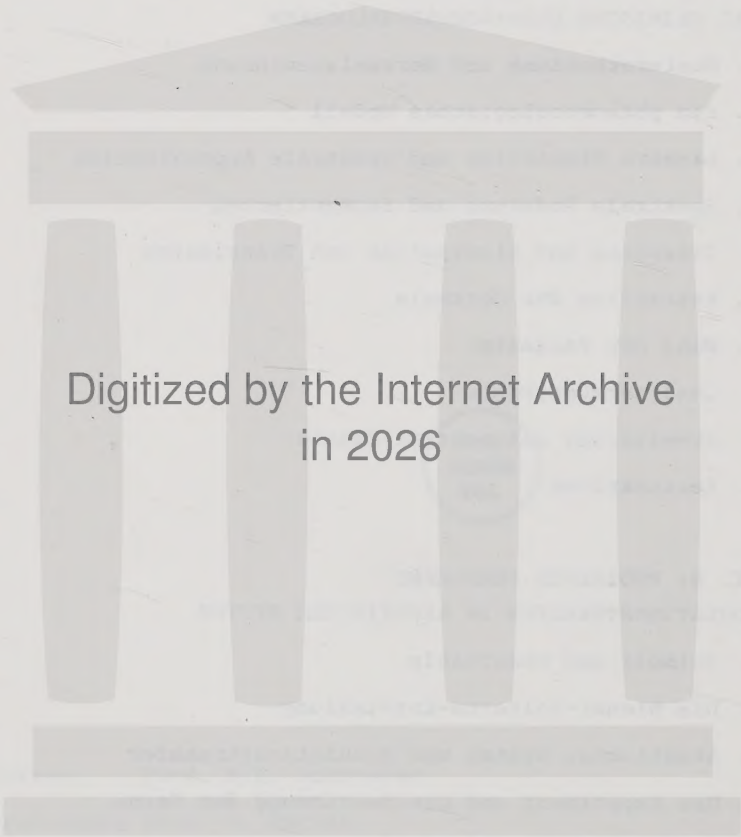
Digitized by the Internet Archive
in 2026

https://archive.org/details/IA41534921_0044

1. Einleitung

Eine enorme Fülle von Daten strömt zu jeder Zeit von unseren Sinnesrezeptoren in unser Gehirn und versorgt uns mit Information über unsere Umwelt. Um es bei einer solchen Datenflut noch zu ermöglichen, komplexe Entscheidungen zu treffen, oder, worauf wir uns hier beschränken wollen, "Muster" zu erkennen, muß eine ganz erhebliche Reduktion der Daten bei möglichst gleichbleibendem Informationsgehalt erfolgen: diesen Schritt wollen wir mit "Merkmalsgewinnung" bezeichnen.

Die vorliegende Arbeit macht den Versuch, diesen Prozeß der Merkmalsgewinnung in zwei Fällen aufzuklären. Im ersten Fall ist das Eingangssignal das klinische Elektroenzephalogramm, und das untersuchte System ist - mangels struktureller Kenntnis des Signals - der Neurologe, der sich bemüht, aus diesen Daten eine Diagnose über den Patienten zu stellen. Im zweiten Fall ist das Eingangssignal ein akustischer Reiz, hier beschränkt auf Amplitudenmodulation, das untersuchte System ist das akustische System am Beispiel des Meerschweinchens.

Um Ordnung in unsere Vorstellungen und Hypothesen zu bringen, ist es sinnvoll, sie in "Modellen" zusammenzufassen. Nun müssen wir uns bei biologischen Systemen über eine prinzipielle Schwierigkeit bewußt sein: sie sind im allgemeinen äußerst komplex. Unglücklicherweise ist es

nicht möglich, die Methoden der Physik zu benutzen, um diese Schwierigkeit auszuräumen: dort bemüht man sich, das zu untersuchende Teilsystem zu isolieren, es also von seinen Wechselwirkungen mit der "Außenwelt" zu befreien. Trivialerweise ist dies bei biologischen Systemen nicht möglich, da hier die Wechselwirkung zwischen verschiedenen Subsystemen integraler Bestandteil des Systems ist; nach Unterbindung derselben haben wir nicht mehr das System vor uns, das uns eigentlich interessiert.

Unter diesen Umständen wird verständlich, daß es schwer sein wird, strukturelle Modelle für neuronale Systeme aufzustellen, also solche, die die Funktion des Systems durch Annahme über seine Struktur erklären. In der vorliegenden Arbeit werden zwei andere Wege eingeschlagen: im ersten Fall, bei der Analyse der EEG-Diagnose, müssen wir auf eine mathematische Beschreibung als Ausgangspunkt völlig verzichten; vielmehr bemühen wir uns, ein "phänomenologisches" Modell aufzustellen, das rein deskriptiv die vom Neurologen vermutlich verwendeten Prozeduren beschreibt, und dies später in einen Algorithmus umzusetzen. Im zweiten Teil haben wir ein, wenn auch stark gestörtes, dynamisches System vor uns; hier werden wir versuchen, die durch das System vermittelte Abbildung zwischen Eingangs- und Ausgangssignal "funktional" zu beschreiben, also durch ein System von Funktionalen, deren Wahl ohne vorherige Annahmen über das System erfolgt. Erst anschließend wird versucht, die so gewonnene Beschreibung in Aussagen über die Struktur des Systems umzusetzen.

TEIL A: SPONTANE PHÄNOMENE

DAS KLINISCHE ELEKTROENZEPHALOGRAMM

2. Mustererkennung und Merkmalsgewinnung

Vor mehr als 50 Jahren gelang es Hans Berger erstmalig, ein Elektroenzephalogramm (EEG) vom Menschen aufzuzeichnen - Schwankungen des elektrischen Potentials auf der Schädelhaut, von denen man damals erhoffte, sie seien in eindeutiger Weise mit verschiedenen psychischen Zuständen des Gehirns verknüpft. Wenngleich diese hochgesteckten Erwartungen sich auch nicht erfüllt haben, so nimmt das EEG heute doch einen wichtigen Platz bei der Diagnose einer Fülle von neurologischen Erkrankungen ein. Die wichtigsten Beispiele seien hier angeführt: Epilepsie, Früherkennung und Lokalisation von Hirntumoren, Bestimmung bzw. Definition der Schlaftiefe, Koma-Überwachung in der Intensivpflege.

Naturgemäß hat es in dieser Zeit nicht an Versuchen gefehlt, neurophysiologische Modelle für die Generation des EEG zu entwickeln. Zwar hat man zeigen können, daß das EEG mit intrazellulär abgeleiteten postsynaptischen Potentialen korreliert ist [4], doch liefert dies nur wenig Information über die Signalstruktur, da das EEG lediglich die Aktivität aufzeigt, die eine große Zahl von Untersystemen gemein hat.

Ziel dieser Arbeit ist es, einen systematischen Ansatz

für die automatische Analyse des klinischen EEG zu liefern mit dem Fernziel einer automatischen Diagnose. Zur Entwicklung eines solchen Systems benötigen wir zunächst ein Modell des zu untersuchenden Signals. Da geeignete strukturelle - etwa neurophysiologische - Modelle nicht vorliegen, werden wir uns mit rein phänomenologischen Modellen begnügen müssen. Die einzige Informationsquelle, die uns hier zur Verfügung steht, ist der für die EEG-Diagnose ausgebildete Neurologe; wir wollen daher mit einer Analyse der von ihm durchgeführten Auswertung beginnen. Die vom Arzt gelieferte Auswertung besteht aus zwei Teilen: Der erste, üblicherweise als "Zusammenfassung" bezeichnete, ist rein deskriptiv, während der zweite (die "Beurteilung") die Diagnose enthält. Dies entspricht gerade dem allgemeinen Schema einer Mustererkennung, das in Fig. 1 dargestellt ist.

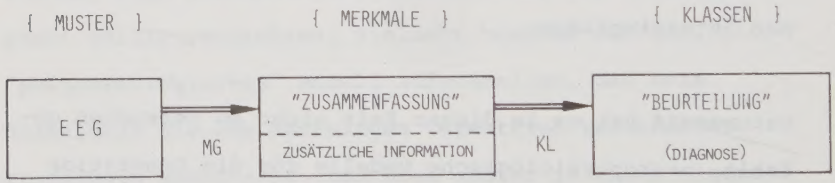

Fig. 1: Allgemeines Schema der Mustererkennung, bezogen auf EEG-Analyse. MG: Merkmalsgewinnung, KL: Klassifikation. "Zusätzliche Information" repräsentiert neurologische Symptomatik und Vorgeschichte.

In diesem Zusammenhang muß allerdings erwähnt werden, daß ein für die Beurteilung außerordentlich wichtiger Faktor die neurologische Symptomatik ist; aus dem EEG allein

eine Diagnose zu stellen, ist fast immer unmöglich (nur etwa 85% der Bevölkerung zeigen ein unauffälliges EEG [12]).

Wie gewinnt nun der Arzt die ihn interessierenden Merkmale aus dem EEG? Bei einer üblichen EEG-Aufnahme werden 8 bis 16 Kanäle gleichzeitig über 10 bis 20 Minuten abgeleitet, was einen Papierstreifen von 18 bis 36 m Länge ergibt. Die Analyse dieses enormen Datenmaterials wird nun dadurch erleichtert, daß sich im Signal fast immer eine gewisse Stationarität erkennen läßt, die sogenannte "Hintergrundaktivität" (Beispiel: α-Rhythmus). Diese stationäre Aktivität wird von Zeit zu Zeit durch das Auftauchen anderer Wellenformen unterbrochen, die als "Paroxysmen" oder, falls sie länger als einige Sekunden andauern, als "Gruppen" bezeichnet werden; sie sind nicht notwendig Anzeichen einer Abnormität und lassen sich beispielsweise in allen Schlafstadien beim gesunden Erwachsenen nachweisen (Fig. 2, D und E). Von besonderer Bedeutung sind die "transienten" Phänomene: einzelne auffällige Wellen, die als "Spikes" (bzw. "Spitzen") oder, bei größerer Wellenlänge, als "Steile Wellen" bezeichnet werden und die auf eine Krampfanfälligkeit (Epilepsie) hindeuten (Fig. 2, A-C und F).

Der Arzt wird nun zunächst den EEG-Ausschrieb durchblättern und nach solchen diagnostisch relevanten Wellenformen Ausschau halten. In der "Zusammenfassung" wird er

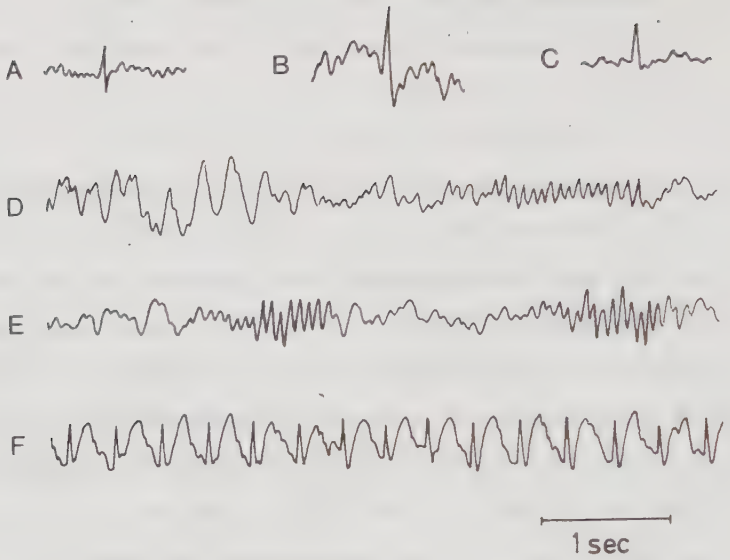

Fig. 2: Einige Beispiele für elementare EEG-Muster. A-C: Transienten. A: Biphasischer Spike ("Spitze"). B: Biphasische Steile Welle. C: Monophasische Steile Welle. D, E: Erwachsener, leichter Schlaf. Man beachte das Auftreten von 13 Hz-Spindeln in beiden Fällen. F: Spike/Wave-Komplexe typisch für die petit-mal Variante, eine Form epileptischer Potentiale. Diese Wellenform kann interpretiert werden als ein Hybrid aus einer 3 Hz Hintergrundaktivität und Spikes, die ihr mit fester Phasenbeziehung überlagert sind. (Aus [12])

die verschiedenen Arten von Aktivität, die er gefunden hat, beschreiben; erst danach wird er mit der diagnostischen Auswertung beginnen. Der wesentliche Punkt hierbei ist, daß er ebenso viel Zeit für die normalerweise seltenen Stücke abnormer Aktivität verwenden wird wie für die "Hintergrundaktivität", deren Informationsgehalt gering ist.

Um nun zu sehen, welche Merkmale aus den einzelnen Stücken extrahiert werden, müssen wir uns der EEG-Terminologie zuwenden. Grundelement ist die "Welle", der Bereich zwischen zwei benachbarten Extrema mit gleichem Vorzeichen. Bei isolierten Nichtstationaritäten ("Transienten") wird die einzelne Welle beschrieben, und zwar durch einen Satz von Graphoelementen, die ihre Form repräsentieren, etwa Höhe und Steilheit. Wo dagegen viele gleichartige Wellen aufeinander folgen, werden sie lediglich durch ihre Länge (d.h. Frequenz) und ihre Amplitude beschrieben. Zusätzlich wird zuweilen die "Regelmäßigkeit" (Breite der Resonanzen), selten die Form (Harmonische) erwähnt. Die Beschreibung im Spektralbereich hat sich als äußerst wichtig herausgestellt; die meisten EEG-Spektren zeigen eine deutliche Resonanzstruktur, und dementsprechend wird der Frequenzbereich gemäß der üblichen Verteilung der Resonanzen (die als "Rhythmen" bezeichnet werden) in diagnostisch relevante Frequenzbänder aufgeteilt, nämlich das delta- (0,5 - 3,5 Hz) theta- (3,5 - 7,5 Hz), alpha- (7,5 - 12,5 Hz) und beta-Band (> 12,5 Hz).

Schließlich noch einige Worte zum augenblicklichen Stand der automatischen EEG-Analyse. Die gebräuchlichen Methoden lassen sich grob in zwei grundlegend verschiedene Gruppen einteilen. Die erste ist Spektralanalyse (entsprechend einer Analyse der Hintergrundaktivität): Hier wird das EEG als stationär, zumindest langsam veränderlich, ange-

sehen. Aus festen Segmenten von etwa 30 sec Länge werden Spektren berechnet. Diese Methode liefert gute Ergebnisse, wenn die Hintergrundaktivität abnorm ist. Anwendungsbeispiele sind Komaüberwachung oder Untersuchungen über den Einfluß von Medikamenten auf das EEG [7]. Die Zeitstruktur des EEG geht jedoch weitgehend verloren. Die zweite Methode ist die Einzelwellenanalyse, in der nach abnormen einzelnen Wellen Ausschau gehalten wird. Das Elementarmuster ist hier die einzelne Welle, die durch einen Satz von Graphoelementen beschrieben wird. Dementsprechend wird, zumindest anfänglich, eine große Zahl von Merkmalen generiert, außerdem sind die einzelnen Wellen nach der Merkmalsgewinnung aus ihrem Kontext herausgelöst. Diese Methode führt zu guten Ergebnissen, wenn eine bestimmte, seltene Wellenform (üblicherweise Transienten) erkannt werden soll [8,10].

3. Ein phänomenologisches Modell

Kommen wir nun zurück auf unser allgemeines Schema einer Mustererkennung: Offenbar ist die Definition eines Musters als "beliebige EEG-Aufzeichnung von 10 Min. Länge" weitaus zu komplex, um uns von Nutzen zu sein. Dementsprechend müssen wir dieses Muster in "Elementare Muster" aufspalten, ebenfalls ein allgemeines Prinzip der Mustererkennung: So muß ein Sprachsignal in die Elementarmuster "Wort" oder "Phonem" segmentiert werden, ein geschriebener Text in "Worte" und diese weiter in "Buchstaben". In Übereinstimmung mit diesem allgemeinen Verfahren postulieren wir folgendes phänomenologische EEG-Modell:

Hypothese I (Segment-Struktur):
Das EEG besteht aus quasi-stationären Segmenten, denen Transienten überlagert sein können. "Quasi-stationär" bedeutet hier, daß das Kurzzeitspektrum sich innerhalb eines Segments nicht wesentlich ändert. "Transienten" sind kurzzeitige Instationaritäten, die aus nur einer oder zwei Wellen bestehen.

Hypothese II (Merkmalsgewinnung):
Ein Segment wird hinreichend beschrieben durch seine Länge sowie durch sein Leistungsspektrum,ein Transient durch einen Satz von Graphoelementen sowie durch den Zeitpunkt seines Auftretens.

Wir wollen nun überlegen, welchen Anforderungen ein auto-

matisches System genügen muß, das entsprechend unserer Modellvorstellung ein EEG analysieren und in der klinischen Routine einsatzfähig sein soll. Hierbei wollen wir uns auf den ersten, rein signalverarbeitenden, Teil beschränken, also Segmentation und anschließende Merkmalsgewinnung. Um in der Wahl der Methoden möglichst frei zu sein, ist der geeignete Prozessor ein Digitalrechner:

(i) Das System muß auf einem Laborrechner implementiert werden können (womöglich mit kleineren Erweiterungen der Hardware).

Weiterhin erfordert die klinische Routine zuverlässige und schnelle Verarbeitung und erlaubt nicht die Verwendung eines Zwischenspeichers (etwa auf Magnetband):

(ii) Die Merkmalsgewinnung muß in Echtzeit erfolgen.

(iii) Das System muß in der Lage sein, jedes eingegebene EEG sinnvoll zu verarbeiten, solange die Aufzeichnungsqualität akzeptabel ist.

Schließlich befinden wir uns im Kontext der Mustererkennung uns müssen daher fordern

(iv) Das Format der Merkmale muß sich als Eingang in Klassifikationsalgorithmen (etwa Clusteranalyse, Diskriminanzanalyse) eignen.

(v) Das System sollte eine hohe Datenreduktion erzielen.

Wir beenden diesen Abschnitt mit einigen allgemeinen Be-

trachtungen über die erforderliche Systemstruktur. Offenbar muß die Methode - schnell und bei geringem Kernspeicherbedarf - drei Aufgaben zugleich erfüllen, nämlich Segmentation, Erkennung von Transienten und Schätzung von Spektren. Dies wird sich nur dann erreichen lassen, wenn ein gemeinsamer Zugang zu diesen Aufgaben gefunden werden kann. Wie in den folgenden vier Abschnitten ausgeführt ist, bedienen wir uns als grundlegenden Hilfsmittels der Methode der Linearen Prädiktion (LP). Dieses Verfahren wurde 1942 von N. Wiener entwickelt [33] und später von Robinson [27] in der Geophysik, von Atal und Schroeder [2] in die Akustik eingeführt. Auch in der EEG-Analyse ist dieses Verfahren verschiedentlich angewandt worden: Gersch [11] führte es ein zur Schätzung von Spektren, Fenwick [9] für Simulation, Lopes da Silva [18] für die Erkennung von Transienten. Seine hier geschilderte Anwendung zur Erkennung von Segmentgrenzen ist darauf ausgelegt, eine Verbindung zwischen den beiden im vorangegangenen Abschnitt geschilderten Methoden zu vermitteln: Instationaritäten wird durch ihre Repräsentation als Segmentgrenzen oder Transienten Rechnung getragen. Die als quasi-stationär vorausgesetzten Segmente bieten sich dann für eine Spektralanalyse mit entsprechend hoher Datenreduktion an; im Gegensatz dazu dürfen die Transienten, die nur vereinzelt auftreten und diagnostisch sehr bedeutend sind, im Zeitbereich durch Graphoelemente beschrieben werden.

4. Lineare Prädiktion und spektrale Approximation

Gegeben seien zwei Zeitfunktionen, x(t) (das "beobachtete Signal") und y(t) (das "gewünschte Signal"). Wiener löste folgendes Problem [33]: Finde ein lineares Filter, H(t), so, daß y(t) durch die Faltung H*x(t) im Sinne eines minimalen quadratischen Fehlers optimal approximiert wird.

Wir nehmen im folgenden an, daß das Zeitsignal zu diskreten Zeiten abgetastet wird, d.h. wir betrachten Zeitreihen $\{x(n)\} = \{\ldots,x(-1),x(o),x(1),\ldots\}$. Weiterhin beschränken wir uns auf den Fall $y(n) = x(n+1)$ und fordern, daß das Wiener-Filter kausal ist: Wir wollen aus der Vergangenheit des Signals seinen nächsten Wert vorhersagen. Man bezeichnet dies als Lineare Prädiktion (LP) [19].

Bezeichne nun $\hat{x}(n)$ den aus $x(n-1), \ldots, x(n-p)$ für $x(n)$ geschätzten Wert:

$$\hat{x}(n) = -\sum_{k=1}^{p} x(n-k)\,a(k) \qquad (4.1)$$

Die Koeffizienten a(k) werden als "Prädiktorkoeffizienten" bezeichnet, p ist die "Filterlänge". Der bei dieser Schätzung gemachte Fehler, der "Prädiktionsfehler" (PF), ist

$$e(n) = x(n)-\hat{x}(n) = \sum_{k=o}^{p} x(n-k)\,a(k) \qquad (4.2)$$

wo $a(o) := 1$. e(n) läßt sich interpretieren als ein Maß

für den Grad von "Überraschung", der im Wert x(n) enthalten ist. Der Erwartungswert des quadrierten Prädiktionsfehlers ist

$$\langle e^2 \rangle = \sum_{k,l=o}^{p} a(k)R(k,l)a(l) \tag{4.3}$$

mit der Autokovarianzmatrix

$$R(k,l) = \langle x(n-k)x(n-l) \rangle \tag{4.4}$$

Differentiation nach den a(k) ($k \neq o$) ergibt die Normalgleichungen

$$\sum_{k=1}^{p} a(k)R(i,k) = -R(o,i), \quad i=1,\ldots,p \tag{4.5}$$

In der Praxis muß die Autokovarianzmatrix aus einem endlichen Stück der Länge N geschätzt werden. Wir benutzen die "Autokorrelationsmethode"

$$R(i,k) = \frac{1}{N} \sum_{n=1}^{N-|i-k|} x(n)x(n+|i-k|) = R(i-k) = R(k-i) \tag{4.6}$$

die die Stabilität des inversen Filters gewährleistet [20]. Weiter wird die Autokovarianzmatrix mit (4.6) streifensymmetrisch, wodurch die extensive Theorie über Toeplitz-Formen [13] anwendbar wird.

Wir wollen nun kurz einige für das folgende wichtige Eigenschaften von LP-Filter und Prädiktionsfehler darstellen.

Dazu eine Vorbemerkung: Die einzige Größe, die zur Berechnung des Prädiktionsfilters benötigt wird, ist die Autokorrelationsfunktion (AKF) des Signals. Auf die mit ihrer Schätzung einhergehenden Probleme wollen wir später eingehen; im Augenblick nehmen wir die AKF als gegeben hin und befinden uns somit im "Autokorrelationsbereich". Der Übergang vom Autokorrelationsbereich in den Spektralbereich (oder allgemeiner, vom Zeitbereich in den Frequenzbereich) wird vermittelt durch das diskrete Analogon zur Fouriertransformation, die "Z-Transformation" $X(z) = \Sigma x(n) z^{-n}$, wo der Einheitskreis ($z = \exp(i\omega)$) der reellen Achse bei der Fouriertransformation entspricht. Dem Prädiktionsfilter $\{a(k)\}$ läßt sich so eine Übertragungsfunktion $A(z)$ zuordnen:

$$x(n) \longrightarrow \boxed{A(z)} \longrightarrow e(n)$$

Wir definieren weiter ein "inverses Filter" durch $A^{-1}(z) := (A(z))^{-1}$:

$$e(n) \longrightarrow \boxed{A^{-1}(z)} \longrightarrow x(n)$$

Sei nun $A_p(z)$ die dem Prädiktionsfilter der Ordnung p, $\{a_p(k)\}$, entsprechende Übertragungsfunktion*. Dann folgt

---

* Die hier verwendete Nomenklatur unterscheidet sich von der normalerweise benutzten auf folgende Weise: Üblicherweise wird $A(z)$ als "inverses Filter" oder "Prädiktionsfehlerfilter" bezeichnet, wohingegen "Prädiktionsfilter" für $A(z)-1$ verwendet wird. "Prädiktor" wird in dieser Arbeit synonom für "Prädiktionsfilter" benutzt.

aus den Normalgleichungen (4.5)

$$\frac{1}{2\pi i} \oint_{|z|=1} z^p A_p(z) \overline{z^q A_q(z)} P(z) \frac{dz}{z} = \sigma_p \sigma_q \delta_{p,q} \qquad (4.7)$$

wo P(z) die Z-transformierte der "wahren" Autokovarianz des unendlich langen (nicht beobachtbaren) Signals ist. Das bedeutet, daß die Polynome $\sigma_p^{-1} z^p A_p(z)$, p=o,1..., bezüglich des Maßes P(z)dz/z auf dem Einheitskreis orthonormal sind. Die Normalisierungsfaktoren σ_p sind gleich der rms-Amplitude des Prädiktionsfehlers und berechnen sich zu

$$\sigma_p^2 = \sum_{k=o}^{p} a_p(k) R(k) \qquad (4.8)$$

Aus (4.7) folgt, daß eine rekursive Prozedur zur Berechnung des Prädiktionsfilters existiert, nämlich durch Orthogonalisierung der Übertragungsfunktionen; man findet [19]

$$A_p(z) = A_{p-1}(z) + k_p z^{-p} A_{p-1}(z^{-1})$$

wo (4.9)

$$k_p = -\sigma_{p-1}^{-2} \sum_{k=o}^{p-1} a_{p-1}(k) R(p-k)$$

Die durch (4.9) gegebene Prozedur wird als Levinson-Algorithmus bezeichnet [17].

Eine wichtige Eigenschaft des inversen Filters ist seine Stabilität: Alle Pole - entsprechend den Nullstellen von

A(z) - liegen innerhalb des Einheitskreises. Da Nullstellen nicht vorkommen, ist das inverse Filter (wie auch das Prädiktionsfilter selbst) sogar minimalphasig. Dies wird der Fall sein, solange $|k_p| < 1$, was während der Berechnung leicht nachgeprüft werden kann.

Die Definition des Prädiktionsfilters war im Zeitbereich motiviert; seine wichtigsten Anwendungen liegen jedoch in der Approximation und Glättung von Spektren: Das normalisierte inverse Filter, $\sigma_p A_p^{-1}(z)$, hat ein Leistungsspektrum

$$\hat{P}_p(\omega) = |\sigma_p A_p^{-1}(e^{2\pi i\omega})|^2 = \frac{\sum_{k=o}^{p} a(k)R(k)}{\left|\sum_{k=o}^{p} a(k)e^{-2\pi ik\omega}\right|^2} \qquad (4.10)$$

das, wie wir nun sehen wollen, eine Approximation an das wahre Signalspektrum, $P(\omega)$, darstellt. Aus den Normalgleichungen folgt, daß die ersten (p+1) AKF-Koeffizienten des normalisierten inversen Filters, $\hat{R}_p(k)$, übereinstimmen mit den ersten (p+1) AKF-Koeffizienten des Signals. Das bedeutet, daß

$$\int (P(\omega)-\hat{P}_p(\omega))\cos 2\pi\omega k \, d\omega = o, \; k=o, \; \ldots, \; p \qquad (4.11)$$

und somit konvergiert das Spektrum des inversen Filters ("LP-Spektrum") mit steigender Filterordnung gegen das Signalspektrum. Gleichzeitig "verliert" der Prädiktionsfehler an Korrelation (die im Signal enthaltenen Korrelationen werden vom Filter absorbiert) und ist, im

Grenzfall $p \to \infty$, weißes Rauschen.

Hier ist ein Vergleich mit den "konventionellen" (FFT-) Methoden der spektralen Schätzung angebracht: Auch dort beginnt man mit der Berechnung einer AKF bis etwa zum Grad p. Die zu $k > p$ gehörigen Werte werden als verschwindend oder periodisch angenommen. Das bedeutet, daß man zur Vermeidung von Abbrucheffekten die AKF für relativ große p kennen muß; Glättung dagegen wird erzielt durch Verwendung entsprechender Fenster im Zeitbereich. Bei der Linearen Prädiktion dagegen werden die unbekannten AKF-Koeffizienten aus dem bekannten Teil vermittels des inversen Filters geschätzt, so daß Abbrucheffekte gar nicht auftreten können.

Wir wollen nun sehen, auf welche Klasse von Spektren die LP-Methode besonders vorteilhaft angewandt werden kann. Ausgehend vom Verfahren der Maximum-Likelihood-Schätzung fanden Itakura und Saito [14] für Gauß'sche Signale eine (angenäherte) Verlustfunktion

$$L = \int (e^{V(\omega)} - V(\omega) - 1)\, d\omega \qquad (4.12)$$

wo $V(\omega) = \log P(\omega) - \log \hat{P}(\omega)$ die Differenz der logarithmischen Spektren ist. Es läßt sich zeigen [20], daß die Minimierung von L auf einen mit (4.5) identischen Satz von Gleichungen führt. Offenbar tragen positive Werte von $V(\omega)$, entsprechend $P(\omega)/\hat{P}(\omega) > 1$, stärker zum Integral

bei als negative: Das Signalspektrum P wird durch das Modellspektrum $\hat{P}$ "von oben" approximiert. Bei steigender Filterordnung werden zunächst die Resonanzen modelliert; das ist nicht erstaunlich, wenn man bedenkt, daß das LP-Spektrum einem Nur-Pol-Modell entspricht, das lediglich mehr oder weniger gedämpfte Resonanzen enthält.

Nun finden wir bei EEG-Spektren typischerweise ein oder zwei ausgeprägte Resonanzen ("Rhythmen"). Approximation "von oben" bedeutet gerade, daß die diagnostisch relevanten Anteile vom Modell als erste erfaßt werden, wohingegen die weniger interessanten Anteile (Abschnitte niedriger Leistung, die ohnehin durch Rauschen kontaminiert sind) weniger Beachtung finden und lediglich geglättet werden. Es ist dies, abgesehen von den Vorzügen einer Darstellung durch nur wenige Parameter, der Grund, warum das Prädiktionsfilter für Anwendungen im EEG-Bereich so gut geeignet ist.

Aus (4.13) läßt sich ein einfacheres Maß für die Güte der spektralen Approximation herleiten, wenn man zunächst die Fehlerleistung auf ihren Minimalwert fixiert (entsprechend der Normalisation $\int \{P(\omega)/\hat{P}(\omega)\}d\omega = 1$ nach (4.7)) und erst dann (4.12) unter dieser Nebenbedingung minimiert; man erhält so das "Spektrale Flachheitsmaß" nach Markel und Gray [20], das nur noch von der Form des Spektrums abhängt und definiert ist durch

$$FM = \frac{\exp \int \log P_e(\omega)\ d\omega}{\int P_e(\omega)\ d\omega} \qquad (4.13)$$

wo $P_e(\omega)$ das Leistungsspektrum des Prädiktionsfehlers ist. Als Quotient aus geometrischem und arithmetischem Mittel nimmt (4.13) seinen Maximalwert von 1 nur für ein konstantes Spektrum an. Die Flachheitsmaße am Eingang, x, und Ausgang, e, eines Prädiktionsfilters sind verknüpft durch

$$FM_e = FM_x \cdot \sigma_x^2/\sigma_e^2 \tag{4.14}$$

wo σ_x^2 und σ_e^2 die Leistungen von Eingangssignal und Prädiktionsfehler darstellen. Bei festem Eingangssignal hängt die Güte der Approximation demnach lediglich von der PF-Leistung ab und nimmt mit steigender Filterordnung - entsprechend fallendem σ_e - zu. Diesen Umstand nutzen die Kriterien von Akaike [1] und Parzen [24] zur Bestimmung der optimalen Zahl von Filterkoeffizienten durch Minimierung der Funktionen

$$AIC(m) = 2\frac{m}{N} - \log\frac{\sigma_\infty^2}{\sigma_m^2} \tag{4.15}$$

bzw.

$$CAT(m) = \frac{m}{N} - \frac{\sigma_\infty^2}{\sigma_m^2} \tag{4.16}$$

Hier ist m die Zahl der Filterkoeffizienten, σ_m^2 die Leistung des entsprechenden Prädiktionsfehlers, N die Länge der zur Berechnung des Prädiktors verwendeten Zeitreihe; σ_∞^2 ergibt sich theoretisch zu $\sigma_\infty^2 = \exp\int \log P(\omega)\, d\omega$.

Am Ende dieses Abschnitts wollen wir die für das folgende wesentlichen Eigenschaften des Prädiktionsfilters nochmals

zusammenfassen:

Das Prädiktionsfilter ist ein lineares Filter, das sich bemüht, das Eingangssignal in (dekorreliertes) weißes Rauschen zu transformieren. Dies geschieht durch Adaptation des Filters an das Spektrum (bzw. die Autokorrelationsfunktion) des Eingangssignals. Bei Erhöhung der Filterordnung wird dem Signal mehr und mehr an spektraler Information entzogen und durch die Filterkoeffizienten repräsentiert. Dieser Prozeß ist illustriert in Fig. 3: Das hypothetische Signalspektrum (oben) wird in zwei Komponenten aufgespalten, das Spektrum des inversen Filters (rechts) und das Prädiktionsfehlerspektrum (links); beide sind hier für verschiedene Filterordnungen gezeigt. Diese grundlegende Eigenschaft des Prädiktionsfilters - der Entzug von Korrelationen aus dem Signal - kann lose auf folgende drei Arten ausgedrückt werden:

1. (Zeitbereich): Der Momentanwert des Prädiktionsfehlers gibt an, wie "unerwartet" der Momentanwert des Signals ist.
2. (Autokorrelationsbereich): Der Prädiktionsfehler ist dekorreliert.
3. (Spektralbereich): Da der Prädiktionsfehler weißes Rauschen ist, liefert das inverse Filter eine Nur-Pol-Darstellung des Signalspektrums, die besonders geeignet ist für die Modellierung von Resonanzen.

Wie in den folgenden drei Abschnitten ausgeführt wird, nutzen wir diese drei Eigenschaften folgendermaßen aus:

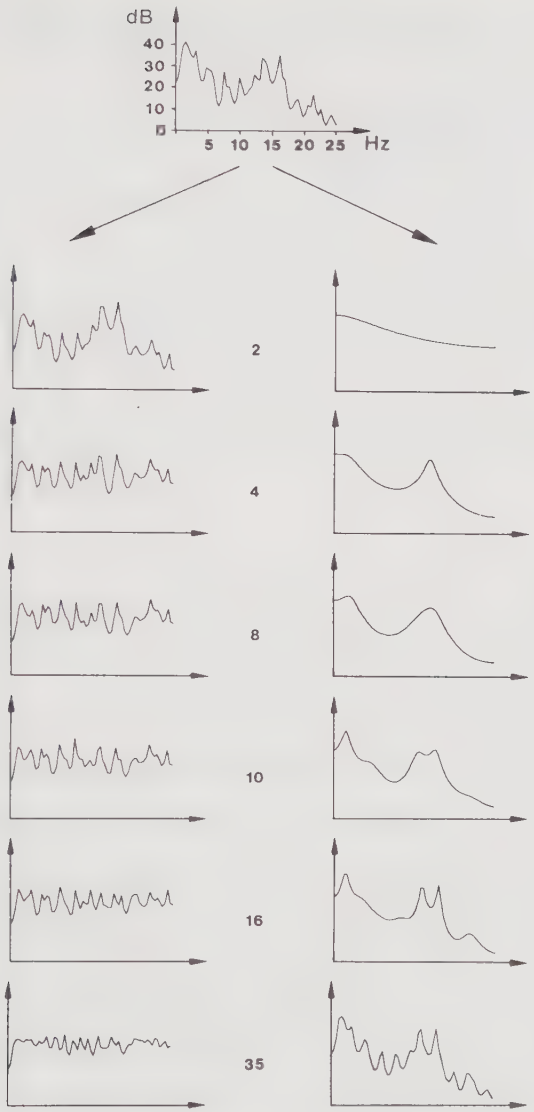

Fig. 3: Spektrale Approximation durch Lineare Prädiktion. Das Signalspektrum (oben) wird aufgespalten in eine mit steigender Prädiktorordnung immer flacher werdende Komponente, das Prädiktionsfehlerspektrum (links), und in eine "glatte" Komponente, das Spektrum des inversen Filters, das durch die Prädiktorkoeffizienten repräsentiert wird. Bei p = 35 enthält das LP-Spektrum bereits zufällige Fluktuationen. Man beachte, daß die Konvergenz für die Resonanzen schneller verläuft als in den "Tälern".

(1) für die Erkennung (und Befreiung) von Transienten;

(2) für die Segmentierung;

(3) für die Merkmalsgewinnung.

5. Spektrale Veränderungen und Segmentierung

Im letzten Abschnitt haben wir gesehen, daß das Prädiktionsfilter uns erlaubt, Zustände durch Spektren zu beschreiben. Unser Hauptanliegen ist aber das der Segmentation, also der Erkennung von Zustandsänderungen. Nachdem wir übereingekommen sind, im Leistungsspektrum den relevanten Zustandsdeskriptor zu sehen, müssen wir demnach ein Maß für spektrale Änderungen entwickeln. Für alle Spektren stehen uns lediglich Kurzzeit-Schätzungen zur Verfügung.

Repräsentiere nun $P_o(\omega)$ den Zustand des Signals zur Zeit t=o, $P_t(\omega)$ zur Zeit t. Wir wollen einen spektralen Fehler von P_t bezüglich P_o definieren. Es erscheint sinnvoll, sich auf solche Abweichungen zu beschränken, die von der Differenz der entsprechenden logarithmischen Spektren (also vom Quotienten $P(\omega) = P_t(\omega)/P_o(\omega)$) abhängen; dies ist eine verbreitete Annahme - etwa in der Akustik - , die sich vorteilhaft auf durch Resonanzen geprägte Spektren anwenden läßt, wo sie verhindert, daß die dominierenden Resonanzen den Einfluß von Gebieten niedriger Leistung völlig zunichte machen.

Diese Annahme stellt unmittelbar den Zusammenhang mit der Methode der Linearen Prädiktion her: Wenn wir ein Prädiktionsfilter an das Spektrum $P_o(\omega)$ adaptieren und anschließend das Signal selbst damit filtern, so wird der

resultierende Prädiktionsfehler ein Kurzzeitspektrum $\hat{P}(\omega) = P_t(\omega)/\hat{P}_o(\omega)$ aufweisen. Durch Wahl einer hinreichend hohen Filterordnung können wir P_o durch $\hat{P}_o$, und damit P durch $\hat{P}$, beliebig genau approximieren. Auf diese Weise läßt sich die Aufgabe, zwei beliebige Spektren miteinander zu vergleichen, in ein kanonisches Problem transformieren, nämlich das, die Abweichung des Quotientenspektrums von einem festen, sogar konstanten, Spektrum zu bestimmen.

Grundlage der folgenden Betrachtungen wird das Integral

$$E(P) = \int (1 - P(\omega))^2 d\omega \qquad (5.1)$$

sein. Um zu sehen, daß sich dieser Ausdruck in einfacher Weise berechnen läßt, gehen wir in den Autokorrelationsbereich über. Sei $\{r(k)\}$ die zu $P(\omega)$ gehörige AKF, also

$$P(\omega) = r(o) + 2 \sum_{k=1}^{\infty} r(k) \cos(2\pi\omega k) \qquad (5.2)$$

Daher ist

$$E(P) = \int (1 - r(o) - 2 \sum_{k=1}^{\infty} r(k) \cos(2\pi\omega k))^2 d\omega \qquad (5.3)$$

und wegen der Orthogonalität der trigonometrischen Funktionen ist

$$E(P) = (1 - r(o))^2 + 2 \sum_{k=1}^{\infty} r^2(k) \qquad (5.4)$$

In der Praxis wird man die Summe bei einer endlichen

Ordnung M abbrechen, was nicht allein eine rechnerische Notwendigkeit ist, sondern auch den Vorzug hat, zufällige Fluktuationen zu verringern. Leider weist das durch (5.1) definierte E(P) eine grundlegende Asymmetrie auf: Wir würden gern $E(P) = E(P^{-1})$ fordern, doch unser Maß ist wesentlich empfindlicher gegenüber einer Erhöhung der Leistung als gegenüber einer Erniedrigung. Wir können dieses unterschiedliche Verhalten jedoch teilweise dadurch ausgleichen, daß wir das Maß mit einer Funktion der Gesamtleistung $\overline{P(\omega)} = r(o)$ normalisieren. Eine Normalisierung mit r(o) selbst führt zur Symmetrie bezüglich Spektren der Form $P(\omega) \equiv \gamma \cdot 1$, doch entsteht bei EEG-Anwendungen die schwierigste, zugleich aber übliche, Situation durch das Auftauchen und entsprechende Verschwinden einer einzelnen ausgeprägten Resonanz (eines "Rhythmus"). Für diesen Fall hat sich eine Normalisierung durch $r(o)^2$ bewährt. Der endgültige Ausdruck für unser spektrales Fehlermaß (SFM) ist daher

$$SFM(P) = \left(\frac{1}{r(o)} - 1\right)^2 + 2 \sum_{k=1}^{M} \left(\frac{r(k)}{r(o)}\right)^2 \qquad (5.5)$$

Hier entspricht der erste Term der Änderung der Leistung des Prädiktionsfehlers, wohingegen der zweite Term allein von der Änderung der Form des Spektrums abhängt.

Wir wollen nun die praktische Ausführung der Segmentierung unter Verwendung des so definierten spektralen Fehlers besprechen. Die Grundidee ist folgende: Man berechne

zunächst zu einem beliebigen Zeitpunkt das (Kurzzeit-) Signalspektrum. Mit Hilfe des SFM vergleiche man damit die zu späteren Zeitpunkten vorliegenden Signalspektren. Das Signal wird nun als "quasi-stationär" definiert, solange das SFM eine gewisse, noch festzusetzende Schwelle Θ nicht überschreitet. Fig. 4 zeigt ein Beispiel: Das EEG (A) besteht aus einer niederfrequenten Grundaktivität, der von Zeit zu Zeit 14 Hz-Spindeln überlagert sind; dies entspricht gerade dem oben erwähnten Fall einer einzelnen ausgeprägten Resonanz, die jedoch nur zeitweise auftritt.

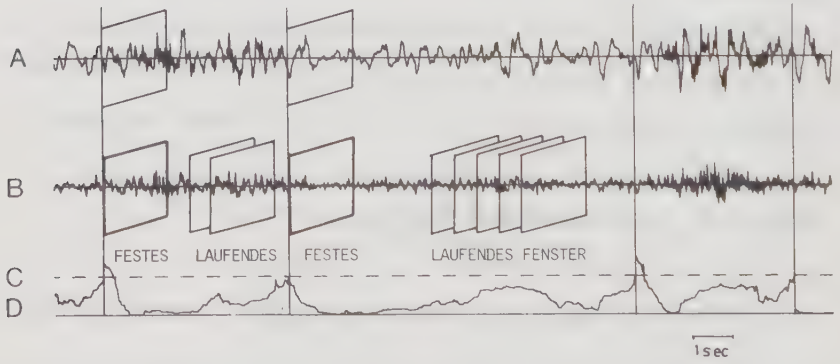

Fig. 4: Ausführung der Segmentierung. A: EEG. Die Trapezoide deuten die Signalstücke an, an die das LP-Filter adaptiert wird. B: Resultierender Prädiktionsfehler. Die anfängliche PF-AKF wird aus dem "festen Fenster" berechnet; die laufende AKF entspricht dem "laufenden Fenster". D: Spektrales Fehlermaß. C: Wert für Θ, die Schwelle für eine Segmentierung.

Die Schritte, die nun im einzelnen ausgeführt werden müssen, sind folgende:

Sei das Eingangssignal repräsentiert durch die Zeitreihe ..., x(-1), x(o), x(1), ... mit beliebigem Nullpunkt.

1. Berechne aus x(-N) ... x(N) entsprechend (4.6) die Signal-AKF der Länge p (Fenster in Fig. 4, Spur A).
2. Berechne mit Hilfe des Levinson-Algorithmus (4.9) das zugehörige Prädiktionsfilter der Ordnung p.
3. Berechne aus den Werten x(-N-p) ... x(n+N) durch Faltung mit dem Prädiktionsfilter entsprechend (4.2) den Prädiktionsfehler e(-N) ... e(n+N) (Fig. 4, Spur B).

In Übereinstimmung mit (4.6) definiere man nun zunächst eine laufende Kurzzeit-AKF (des Prädiktionsfehlers) durch

$$r(n;m) = \frac{1}{2N+1} \sum_{k=-N}^{N-m} e(n+k)\,e(n+k+m) \qquad (5.6)$$

4. Berechne r(o;m) für m=o, ..., M (Fig. 4, Spur B, "festes Fenster").
5. Berechne r(n;m) nach der Rekursion

$$r(n;m) = r(n-1;m) + e(n+N)\,e(n+N-m) - e(n-N-1)\,e(n+m-N-1) \qquad (5.7)$$

(Fig. 4, Spur B, "laufendes Fenster").

Man definiere in Übereinstimmung mit (5.5) ein spektrales Fehlermaß im Punkt n durch

$$SFM(n) = \left(1 - \frac{r(o;o)}{r(n;o)}\right)^2 + 2 \sum_{k=1}^{M} \cdot \left(\frac{r(n;k)}{r(n;o)}\right)^2 \qquad (5.8)$$

6. Berechne SFM(n) nach (5.8) (Fig. 4, Spur D)

7. Prüfe, ob

$$SFM(n) > \theta \tag{5.9}$$

(Fig. 4, Spur C).

Falls (5.9) nicht erfüllt ist, erhöhe n um 1 und kehre zurück zu Schritt (5).

8. Im Zeitpunkt n ist eine Segmentgrenze erkannt worden (angedeutet durch eine vertikale Linie in Fig. 4). Man nehme nun eine Umindizierung der Zeitachse durch die Substitution $(n+k) \rightarrow (k-\hat{N})$ vor und beginne wieder mit Schritt (1).

6. Erkennung und Elimination von Transienten

Die eben eingeführte Segmentierungsprozedur setzt voraus, daß die Signalstatistik 2. Ordnung nach Erreichen eines neuen Zustandes für einige Sekunden konstant bleibt. Sie wird daher durch das Auftreten von kurzzeitigen Instationaritäten stark gestört werden; solche "Transienten" haben eine typische Länge von 100 msec oder darunter. Ein Beispiel ist in Fig. 5 angeführt: Spur A zeigt ein EEG vom burst-suppression-Typ. Die anfängliche Periode der "Unterdrückung" wird unterbrochen durch eine Steile Welle (Zeitpunkt 1), kurz darauf folgt der "burst" (Zeitpunkt 2). Das Prädiktionsfilter wurde an das "unterdrückte" EEG adaptiert. Das resultierende SFM zeigt deutliche Sprünge (Zeitpunkte 3 und 4 in Spur B), wo das laufende Fenster die Steile Welle erreicht und wieder verläßt; die Fensterlänge beträgt hier 2 sec. Dies würde zu einer sinnlosen Segmentierung im Zeitpunkt 3 führen. Der Grund für dieses Verhalten wird durch Untersuchung des Prädiktionsfehlers (Spur C) klar: Der Transient führt zu isolierten hohen Werten des Prädiktionsfehlers, die wiederum in einem konstanten, hohen Wert des Leistungsterms des SFM resultieren, solange der Transient im laufenden Fenster enthalten ist. Nun bietet sich folgende einfache Methode an, um diesem Umstand abzuhelfen: Wir begrenzen die Momentanleistung des Prädiktionsfehlers durch

$$e(n) = \begin{cases} e(n), & |e(n)| < \theta \\ \theta \cdot \mathrm{sign}(e(n)), & |e(n)| \geq \theta \end{cases} \qquad (6.1)$$

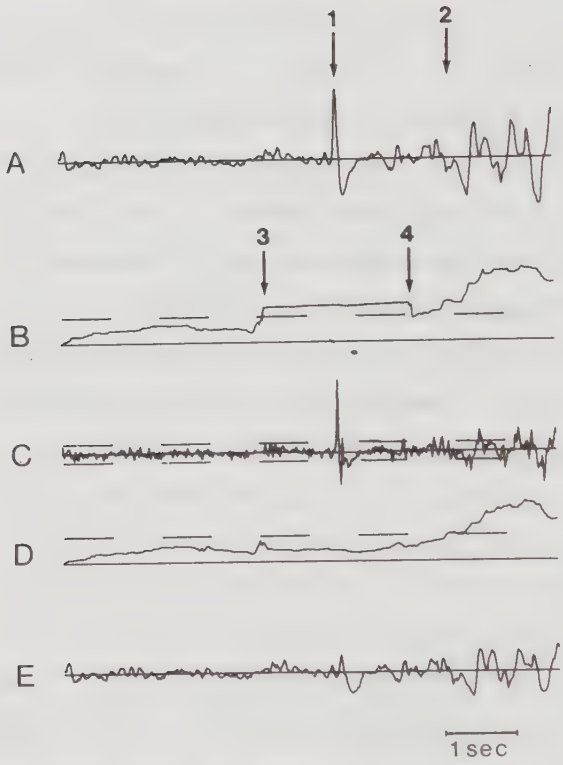

Fig. 5: Elimination von Transienten durch Begrenzung des Prädiktionsfehlers. A: EEG vom burst-suppression-Typ. Nach einer Steilen Welle (1) folgt der "burst" (2). Die Steile Welle führt zu Sprüngen im SFM (Spur B, Zeitpunkte 3 und 4), die nach Begrenzung des PF (C) bei dem durch gestrichelte Linien angedeuteten Schwellwert nicht mehr vorhanden sind (D). Segmentierung erfolgt nun zum Zeitpunkt 2. Spur E: Rekonstruktion des Signals aus dem begrenzten PF. Man beachte, daß ohne Segmentierung die gesamte burst-Periode als nichtstationär eliminiert werden würde.

mit einem geeigneten Schwellwert θ, in Fig. 5, Spur C, durch gestrichelte Linien angedeutet. Spur D zeigt das aus dem begrenzten Prädiktionsfehler gewonnene SFM. Die Sprünge sind verschwunden, und die Segmentierung erfolgt, wie gewünscht, zum Zeitpunkt 2. Das aus dem begrenzten Prädiktionsfehler rekonstruierte Signal ist in Spur E dargestellt; innerhalb der "unterdrückten" Periode ist lediglich die Leistung der Steilen Welle erniedrigt, der Rest des Signals bleibt unverändert.

Nachdem wir gesehen haben, wie wir die Beeinflussung der Segmentierung durch Transienten verhindern können, stellt sich offensichtlich die Frage, ob wir auf diese Weise auch Transienten erkennen und beschreiben können: Ist (6.1) eine vernünftige Definition für einen Transienten?

Wir erinnern uns, daß ganz allgemein Transienten solche Wellenformen sind, die isoliert auftreten und sich durch hohe Amplitude und/oder steilen Anstieg bzw. Abfall auszeichnen. Jedoch kann man ihnen keine deterministische Form zuschreiben, und dementsprechend sind Versuche, "matched" Filter zu ihrer Erkennung zu verwenden, relativ erfolglos geblieben [18]. Weiterhin müssen, wie schon in Abschnitt 2 erwähnt, alle "Wellen" in ihrem Kontext gesehen werden; der Arzt sieht die "steilen" Wellen innerhalb der burst-Periode in Fig. 5 nicht als solche an aus dem einfachen Grund, daß sie nicht isoliert auftreten. Stattdessen wird der "burst" als Ausdruck einer neuen Art

von Hirnaktivität angesehen, was innerhalb unseres Formalismus durch ein neues quasi-stationäres Segment ausgedrückt wird.

Wie in Abschnitt 4 bemerkt, kann der Momentanwert des Prädiktionsfehlers als Maß für die "Überraschung" über den momentanen Signalwert angesehen werden - "Überraschung" bezüglich der im zur Adaptation benutzten Signalstück gefundenen Aktivität. In diesem Sinn ist der Prädiktionsfehler in der Tat ein guter Indikator für nichtstationäres Verhalten: Er wird empfindlich auf hohe Steilheit und Amplitude reagieren, vorausgesetzt, die Wellenlänge ist verschieden von denen im Adaptationsbereich. Auf diese Weise liefert uns die Begrenzung des Prädiktionsfehlers die gewünschte Aufspaltung des Signals in einen quasi-stationären Teil (unterhalb des Schwellwerts) und lokale Instationaritäten (oberhalb des Schwellwerts).

Die Erfahrung hat jedoch gezeigt, daß das Kriterium (6.1) mit einer Wahl des Schwellwerts, die für die Segmentierung geeignet ist, wesentlich zu empfindlich für die Transientenerkennung ist. "Spikes" haben eine Länge zwischen 50 und 100 msec; um einen zu häufigen "falschen Alarm" infolge von zufälligen Fluktuationen im Prädiktionsfehler zu verhindern, können wir daher einfach die Prädiktionsfehlerleistung mit einer entsprechenden Zeitkonstante tiefpaßfiltern. Wir benutzen dementsprechend folgendes

heuristische Kriterium [18]: Berechne

$$sp(n) = e^2(n-1) + 2e^2(n) + e^2(n+1) \qquad (6.2)$$

für solche e(k), für die $|e(k)| \geq \theta$. Wenn dann

$$sp(n) > \hat{\theta} \qquad (6.3)$$

mit einem weiteren Schwellwert $\hat{\theta}$ erfüllt ist, wird das Tripel {x(n-1), x(n), x(n+1)} von Signalwerten als "Spike" bezeichnet und als Teil eines Transienten klassifiziert.

An dieser Stelle ist es instruktiv, sich klarzumachen, wie Segmentation und Transientenerkennung miteinander verzahnt sind: Wir hatten schon gesehen, daß Segmentierung ohne vorherige Befreiung von Transienten zu sinnlosen Ergebnissen führen kann. Die Umkehrung gilt jedoch auch: Wenn sich die Hintergrundaktivität ändert und das Prädiktionsfilter nicht an diesen neuen Zustand des Signals adaptiert wird, kann es vorkommen, daß daraufhin das gesamte folgende Signalstück als transient klassifiziert wird. Dies läßt sich in Fig. 5 verfolgen: Wenn zum Zeitpunkt 2 keine Segmentierung - und dementsprechend keine neue Adaptation des Prädiktionsfilters - erfolgen würde, dann müßte die gesamte "burst"-Periode als ein Satz aufeinander folgender Steiler Wellen angesehen werden.

7. Extraktion der Merkmale

Der Prozeß der Merkmalsgewinnung gliedert sich entsprechend unserer Modellvorstellung in zwei Teile, nämlich Beschreibung der erkannten quasi-stationären Segmente und, falls erforderlich, Beschreibung von Transienten.

Wir beginnen mit den Segmenten: Hier müssen wir das Leistungsspektrum schätzen, und wie wir in Abschnitt 4 gesehen haben, liefern LP-Spektren eine vernünftige Schätzung mit dem zusätzlichen Vorteil, daß der Merkmalssatz relativ kurz und seine Länge konstant ist (insbesondere also unabhängig von der Segmentlänge); dies ist wichtig für eine spätere Weiterverarbeitung mit Klassifikationsalgorithmen.

Nun hatten wir bei der Segmentation schon eine Signal-AKF sowie den entsprechenden Prädiktor der Länge p aus einem Signalstück der Länge (2N+1) gewonnen. Zwar wird sich das daraus gewonnene Spektrum vom Spektrum des Gesamtsegments normalerweise nur unwesentlich unterscheiden - anderenfalls wird ja segmentiert -, dennoch wäre es wünschenswert, einen Korrekturterm anzubringen, der solche Abweichungen berücksichtigt; das ist insbesondere dann unabdingbar, wenn Transienten in dem zur Adaptation des Filters verwendeten Signalstück vorkommen. Speziell in diesem Fall scheidet auch die (aufwendige) Möglichkeit

aus, einfach aus dem segmentierten Signal erneut eine AKF und daraus ein LP-Filter zu gewinnen; vielmehr sollten wir zur Ableitung der Korrektur den begrenzten Prädiktionsfehler benutzen.

Hier kommt uns zugute, daß wir bei der Segmentation schon eine "laufende" AKF des Prädiktionsfehlers berechnet hatten. Diese zu kumulieren, erfordert lediglich Additionen und somit wenig Rechenzeit. Auf diese Weise gewinnen wir einen Fehler-Prädiktor $\{\hat{\sigma};\hat{a}(1)\ldots\hat{a}(M)\}$ der Länge M. Dieser ist, wie auch der Signal-Prädiktor, minimalphasig; daher ist auch ihre Faltung (die im allgemeinen nicht exakt mit dem optimal an das ganze Segment adaptierten Prädiktor übereinstimmen wird) minimalphasig und liefert ein stabiles inverses Filter, wie es für eine sinnvolle Schätzung des Spektrums notwendig ist. Damit hat der gesamte extrahierte Merkmalssatz die Länge (p+M+3) und besteht aus

(i) der Segmentlänge, L;

(ii) dem "Signal-Prädiktor" $\{\sigma;a(1)\ldots a(p)\}$;

(iii) dem "Fehler-Prädiktor" $\{\hat{\sigma};\hat{a}(1)\ldots\hat{a}(M)\}$.

Der endgültige Merkmalssatz, der für die spätere Klassifikation benutzt wird, kann im Anschluß an die Echtzeitverarbeitung des EEG berechnet werden. Vorläufige Klassifikationsversuche ([24]; siehe auch Fig. 7) legen nahe, entweder den "totalen Prädiktor" $\{\bar{\sigma};\bar{a}(1)\ldots\bar{a}(p+M)\}$, wo $\bar{\sigma} = \sigma\cdot\hat{\sigma}$, $\bar{a}(n) = \sum_{m=o} a(n-m)\hat{a}(m)$, zu benutzen, oder aber das "Cepstrum" $\{c(o)\ldots c(p+M)\}$, das definiert ist durch

$c(n) = \int \log A(e^{2\pi i\omega}) e^{2\pi in\omega} d\omega$. Das Cepstrum läßt sich rekursiv aus dem Prädiktor berechnen nach $c(n) = -\bar{a}(n) - \sum_{m=1}^{n-1} c(m)\bar{a}(n-m)$, $c(o) = \log\bar{\sigma}$. Sie sind anderen, äquivalenten Merkmalssätzen - etwa AKF- oder ParCor-Koeffizienten (siehe [19] für ihre Definition) - überlegen.

Es verbleibt das Problem der Merkmalsgewinnung für Transienten, die wir durch Graphoelemente beschreiben wollten. Überlegen wir also, was die wichtigsten Merkmale an einem Transienten sind: Für den einfachsten Fall, einen "monophasischen Spike", kommen Höhe, Breite, Anstiegs- und Abfallssteilheit sowie Krümmung in Frage. Nun sind solche Spikes selten länger als 100 msec; die obige Parametrisierung durch fünf Merkmale liefert daher bei einem Abtastintervall von 20 msec keinen Gewinn gegenüber einer direkten Speicherung der Signalwerte bzw. des Prädiktionsfehlers.

Um nun eine fortlaufende Reihe von Signalwerten als einen Transienten zu definieren, gehen wir folgendermaßen vor: Sei i der erste Zeitpunkt, in dem (6.3) erfüllt ist. Ein "Transient" ist der Datensatz {i-1; e(i-1),e(i), e(i+1)...e(i+k+1)}, wo jedes e(n) in zumindest einem Tripel enthalten ist, das zu einer Überschreitung des Schwellwertes durch die Funktion sp führt. Offenbar ist dazu lediglich erforderlich, daß jeder dritte Wert von sp die Schwelle überschreitet; dies verhindert, daß

ansteigende und abfallende Flanke eines Transienten als zwei verschiedene Transienten angesehen werden. Die ursprüngliche Form des Transienten kann später durch Filterung des gespeicherten Fehlersignals mit dem inversen Signal-Prädiktor zurückgewonnen werden, was sich rekursiv durchführen läßt.

Um darzustellen, wie die verschiedenen Teile des Systems - nämlich Segmentation, Erkennung von Transienten und Merkmalsgewinnung - miteinander verzahnt sind, ist ein (etwas vereinfachtes) Flußdiagramm der gesamten Prozedur in Fig. 6 gezeigt.

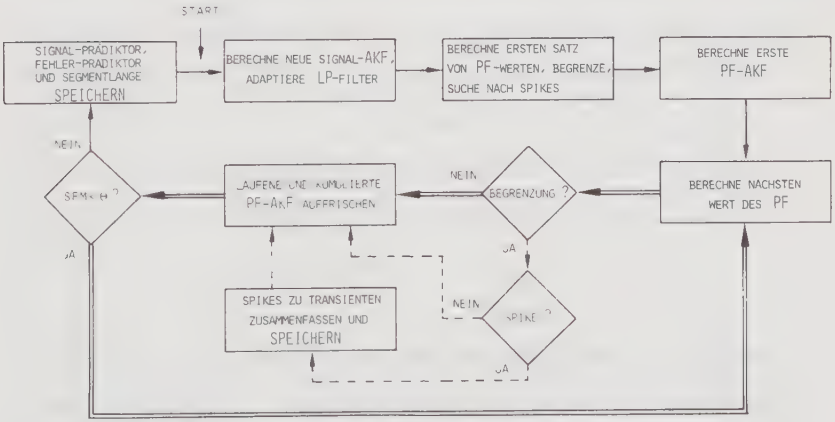

Fig. 6: Zur besseren Darstellung leicht vereinfachtes Flußdiagramm des Algorithmus zur Merkmalsgewinnung. Einfache Pfeile müssen für jedes Segment, Doppelpfeile für jeden Datenpunkt (mit Ausnahme derer im Adaptationsfenster) durchlaufen werden. Die gestrichelten Pfeile werden nur dann durchlaufen, wenn Verdacht auf einen Transienten besteht.

Die Schleife wird erstmalig beim Pfeil "Start" (oben) betreten. Eine einzelne Linie deutet an, welche Operationen einmal für jedes Segment auszuführen sind. Die durch Doppelpfeile gekennzeichnete Schleife muß für jeden neuen Datenpunkt (mit Ausnahme derer, die schon während der Adaptation berücksichtigt wurden) durchlaufen werden. Die gestrichelten Linien zeigen den Umweg, der nur bei Verdacht auf Transienten beschritten werden muß.

8. Wahl der Parameter

In diesem Abschnitt wollen wir die quantitative Festsetzung der bislang definierten Systemparameter besprechen. Das von uns verwendete Modell ist - mit Absicht - sehr allgemeiner Natur; dementsprechend können die optimalen Werte nicht allein anhand theoretischer Überlegungen bestimmt werden, sondern lediglich auf Grund der in Experimenten gewonnenen Erfahrungen.

Wir beginnen mit der Vorverarbeitung: Wir müssen das Signal filtern, abtasten und digitalisieren. Sei ω die untere, Ω die obere Grenzfrequenz des Filters. Die Länge des für die Segmentation verwendeten Fensters nimmt mit steigendem ω ab, was zu exakterer Segmentation führt; daher sollte ω so groß wie nur möglich gewählt werden. Die Zahl der erforderlichen Rechenoperationen steigt stärker als linear mit Ω, das daher niedrig gehalten werden sollte.

Das diagnostisch relevante Frequenzband des EEG liegt nach allgemeiner Übereinstimmung zwischen 0,5 und 30 Hz, wobei sowohl der untere als auch der obere Teil häufig durch Artefakte kontaminiert sind: Im Bereich 0 - 1 Hz sind dies etwa Kopf- und Augenbewegungen, Atmung und arterielle Pulsationen; im Bereich oberhalb von 20 Hz finden wir Muskelaktionspotentiale, insbesondere bei unruhigen Patienten (etwa Kindern). Unter diesen Umständen

erscheint die Wahl $\omega = 1$ Hz, $\Omega = 25$ Hz als vernünftiger Kompromiß. Als Abtastrate dürfen wir somit 50 Hz verwenden; der verbleibende Alias ist vernachlässigbar, da EEG-Spektren zu hohen Frequenzen hin stark abfallen. In diesem Zusammenhang merken wir nochmals an, daß es nicht so sehr Sinn des Verfahrens ist, exzellente Spektren zu berechnen, sondern vielmehr solche Merkmale zu extrahieren, die sich als Datensatz für eine nachfolgende Klassifikation eignen.

Als nächstes kommen wir zur Fensterlänge, $2N + 1$. Sie sollte kurz für eine genaue Segmentation, lang für eine zuverlässige Schätzung der AKF sein. Wir wählen $N = 50$, was einer Fensterlänge von 2 sec entspricht. Der zu erwartende AKF-Meßfehler beträgt damit 10% von $R(o)$, was für unsere Zwecke hinreichend ist (siehe unten); auch die Grundlinienschwankungen halten sich - bei der obigen Wahl von ω - in erträglichen Grenzen. Schließlich entspricht die resultierende Unschärfe von 1 sec in der Segmentation in vielen Fällen den im Signal erkennbaren Übergangslängen.

Wichtigster Systemparameter ist p, die Ordnung des Signal-Prädiktors. Die Zahl der Operationen im Levinson-Algorithmus ist proportional zu p^2, so daß p niedrig gehalten werden sollte. Die Anforderungen an den Prädiktor sind, daß er einen für die Klassifikation hinreichenden Merkmalssatz abgibt und daß der Prädiktionsfehler hinreichend

dekorreliert ist in dem Sinn, daß die Quadratsumme seiner AKF-Koeffizienten (zweiter Term in (5.8)) klein gegenüber θ ist.

Als Faustregel gilt, daß die Zahl der Prädiktorkoeffizienten mindestens doppelt so groß sein sollte wie die Zahl der im Leistungsspektrum erwarteten Resonanzen. EEG-Spektren fallen zu hohen Frequenzen hin ab, haben also ihr Maximum in der Nähe der unteren Grenzfrequenz; dazu kommen typischerweise vier Resonanzen, nämlich jeweils eine im δ-, θ-, α- und β-Band, so daß wir mit einem Bedarf von 10, eher 15, Koeffizienten rechnen müssen. Diese Zahl wird in der Literatur allgemein bestätigt [11,26].

Nun ist ein wesentlicher Vorteil unseres Verfahrens, daß wir infolge der Segmentation mit weniger Koeffizienten auskommen: In der herkömmlichen Spektralanalyse des EEG wird über Zeiträume von etwa 30 sec gemittelt und damit häufig über mehrere "Muster" mit verschiedenen individuellen Spektren. Nun zeigt die Erfahrung, daß im EEG nur selten mehr als zwei Resonanzen gleichzeitig auftreten (im Sprachgebrauch des Neurologen: eine "schnelle" Aktivität ist der "langsamen" überlagert). Durch die Segmentation verhindern wir, daß über verschiedene "Muster" gemittelt wird, was zusammen mit dem Gipfel bei der unteren Grenzfrequenz einen Mindestbedarf von nur 6 Koeffizienten ergibt. Eine Überprüfung mit Hilfe der Kriterien von Akaike und Parzen (Formeln 4.15 und 4.16) hat dies be-

stätigt: sie liefern ein optimales p zwischen 6 und 8. Um sicher zu gehen, wählen wir daher p = 8.

In diesem Zusammenhang erscheinen einige zusätzliche Bemerkungen zur Vorverarbeitung angebracht. Offenbar werden immer zwei Pole dafür verschwendet, den Gipfel bei der unteren Grenzfrequenz nachzubilden, der keine oder nur geringe Information enthält. Theoretische Überlegungen (vgl. 4.14) wie auch die Erfahrung zeigen, daß es angebracht ist, das Signal vor der Prädiktorberechnung "anzuweißen", also möglichst flach zu machen. Bei EEG-Spektren gelingt dies in einfacher Weise durch Differenzenbildung nach dem Abtasten, was einer Multiplikation mit dem Spektrum $1/(1-\exp(-2\pi i\omega))^2$ entspricht. Danach liefern die Kriterien von Akaike und Parzen in der Tat häufig eine Erniedrigung der Prädiktorordnung um 1 bis 2 Koeffizienten; zuweilen allerdings steigt die Ordnung $\to \infty$, was vermutlich darauf zurückzuführen ist, daß der Levinson-Algorithmus nun versucht, die Nullstelle bei der Frequenz $\omega = o$ in Pole zu entwickeln. Diese Schwierigkeit läßt sich jedoch leicht beheben, indem man das "Loch" im Spektrum durch eine geeignete, feste Funktion auffüllt: etwa mit einem Dreieck, was sich durch Addition einer Funktion des Typs $(\sin\lambda n/\lambda n)^2$ zur Signal-AKF erreichen läßt. Dies hat den weiteren Vorzug, daß es den Einfluß aller niederfrequenter Komponenten, die nach der analogen Bandpaßfilterung eventuell noch vorhanden sind, stark reduziert, so daß sie die Segmentation nicht mehr stören können.

Mit p eng verknüpft ist M, die Länge der Prädiktionsfehler-AKF und zugleich die Ordnung des korrektiven Fehler-Prädiktors. Offenbar wird durch AKF-Koeffizienten mit niedrigem Argument eher die Gesamtform des Spektrums analysiert, während die mit großem Argument sensitiv auf die Feinstruktur und damit auf die dort auftretenden zufälligen Fluktuationen reagieren werden. Ein geeigneter Wert scheint M = 3 zu sein. Der resultierende Fehler-Prädiktor enthält somit drei Pole: einer wird auf der reellen Achse liegen, wo er den allgemeinen Abfall zu hohen Frequenzen hin korrigiert, das verbleibende Paar ermöglicht es, eine vorhandene Resonanz zu verstärken bzw. eine noch nicht erfaßte Resonanz darzustellen. Einbrüche im Spektrum können so nicht dargestellt werden, doch da wir mit einer kumulierten AKF arbeiten, können diese ohnehin nicht sehr ausgeprägt sein.

Der "totale" Prädiktor hat nun die Ordnung p + M = 11. Das wesentliche Problem ist, wie oben erwähnt, ob dieser Merkmalssatz für eine Klassifikation hinreichend ist. Fig. 7 zeigt ein Beispiel: Hier ist, für verschiedene Merkmalssätze, die Abhängigkeit der Reklassifikationsrate von der Dimension des Merkmalssatzes angegeben. Die besten Ergebnisse werden mit Cepstrum und Prädiktorkoeffizienten erzielt. Eine Erhöhung der Dimension über 11 hinaus liefert nur wenig an zusätzlicher Information. Die Merkmalssätze wurden unter Verwendung konventioneller Methoden (feste Segmente der Länge 20 sec) extrahiert [25], und die

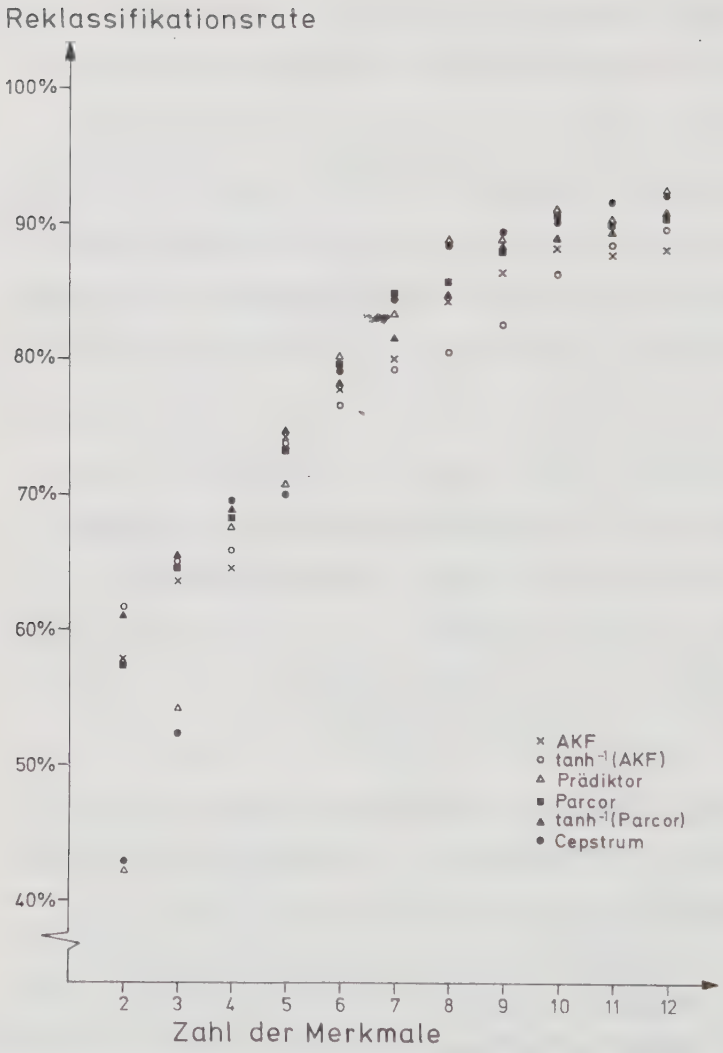

Fig. 7: Abhängigkeit der Reklassifikationsrate vom gewählten Merkmalssatz und seiner Dimensionalität (siehe [19] für die entsprechenden Definitionen). Quadratischer Klassifikator, vier verschiedenen Altersgruppen entsprechende Klassen mit je 85 artefaktfreien, ausgewählten Segmenten von 20 sec Länge (aus [25]).

resultierende Schätzung der optimalen Dimensionalität sollte dementsprechend, wie oben erläutert, als konservativ angesehen werden.

Die Wahl der für die Segmentation verwendeten Schwelle, θ, wird von unten durch das Meßrauschen der AKF begrenzt. Unter der Annahme $\mathrm{var}(R(n)) \hat{=} R^2(o)/(2N+1)$ und einer χ^2-Verteilung für den erwarteten Wert des SFM erhalten wir bei dekorreliertem Fehlersignal ein $SFM_{min} \hat{=} (M+1)/2N+1) \hat{=}$ 0,04. Eine theoretische Begründung für den Optimalwert von θ zu geben, ist jedoch nicht möglich, da wir "quasi-stationär" bislang nur qualitativ definiert haben. Wir benutzen $\theta = 0{,}5$, was sinnvolle Ergebnisse für alle untersuchten EEG-Varianten liefert. Falls sich nur die Signalenergie ändert, entspricht dies einem Anstieg um 5,3 bzw. einem Abfall um 2,3 dB.

Der zur Elimination von Transienten benutzte Schwellwert, θ, ist relativ unkritisch. Wir wählen $\theta = 2{,}5\sigma$, wo σ die rms-Amplitude des Prädiktionsfehlers ist. Bei stationärem und normalverteiltem Prädiktionsfehler bedeutet das, daß etwa 1% der Werte begrenzt werden, also im Mittel nur ein einziger Wert innerhalb des Fensters, so daß in diesem Fall die Schätzung der Prädiktionsfehler-AKF nicht wesentlich beeinflußt wird.

Die bisherigen, an begrenztem Datenmaterial gewonnenen Erfahrungen reichen nicht aus, einen Wert für $\hat{\theta}$, den Schwell-

wert für Transientenerkennung, festzulegen. $\hat{\theta}$ sollte so groß wie möglich gewählt werden, da dieser Parameter zwar nicht rechen-, aber speicherintensiv ist. $\hat{\theta} = 20...40\sigma^2$ scheint eine vernünftige Wahl zu sein.

Schließlich bemerken wir noch, daß sich sowohl die Genauigkeit der Segmentation als auch die Schätzung der Spektren durch Einführung eines weiteren Parameters, der "Übergangslänge" T, verbessern läßt. T ist definiert als die Verzögerung zwischen letzter erkannter Mustergrenze und dem Beginn des nachfolgenden "festen Fensters" (vgl. Fig. 4). Eine solche Verzögerung wird die Wahrscheinlichkeit verringern, daß spektrale Komponenten aus dem vorangegangenen Segment noch in dem zur Adaptation des neuen Prädiktors verwendeten Signalstück vorhanden sind. Ein Wert von T = 25 hat sich bewährt.

9. Qualitätskontrolle

Zunächst wollen wir anhand eines Beispiels für die Segmentation die Validität einiger unserer Annahmen demonstrieren. Fig. 8 zeigt in Spur A ein Kinder-EEG mit eingestreuten 14 Hz-Schlafspindeln; man erkennt deutlich das Alternieren zwischen zwei Zuständen. Das SFM ist in Spur B aufgetragen, die gestrichelte Linie entspricht dem Schwellwert $\theta = 0{,}5$. In D und E sind getrennt die Änderung in der Leistung des Prädiktionsfehlers (D, erster Term in (5.8)) und in der Form des Spektrums (E, zweiter Term in (5.8)) dargestellt. Offenbar ist die Filterordnung $p = 8$ ausreichend, um die im Prädiktionsfehler verbleibenden Korrelationen hinreichend niedrig zu halten. Der Wert des SFM im Adaptationspunkt

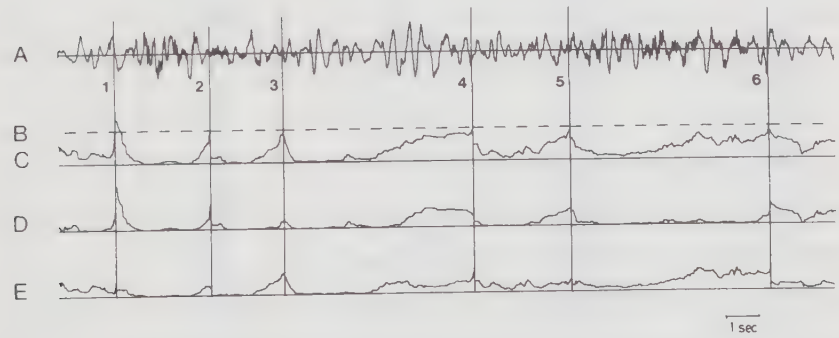

Fig. 8: Verlauf des Spektralen Fehlermaßes. A: Kinder-EEG, Schlafstadium I; Auftreten von 14 Hz-Spindeln. B: Schwellwert für Segmentation. C: SFM. D: Abweichung der PF-Leistung. E: Abweichung in der Form des Spektrums. Vertikale Linien: Segmentgrenzen.

(1 sec hinter den jeweiligen, durch vertikale Linien angedeuteten, Segmentgrenzen) liegt bei oder sogar unter dem im letzten Abschnitt angegebenen Wert von 0,04. Daß die Annahme quasi-stationärer Segmente gerechtfertigt ist, sieht man, wenn man den Verlauf des SFM in den Segmenten 2, 3 und 4 verfolgt, wo es über 1 - 2 sec nahe seinem Wert im Adaptationspunkt bleibt. Segment 4 läßt erkennen, wie willkürlich die Wahl von Θ ist: Bei einem etwas niedrigeren Wert würde eine Segmentation schon kurz nach der Mitte erfolgen, doch würden verschiedene Neurologen ebenfalls unterschiedlich verfahren. Man beachte, daß das SFM nach dem Anstieg wieder einen festen Wert annimmt, dem nur wenig Rauschen überlagert ist; die endgültige Segmentation erfolgt dann mit dem Einsatz der β-Spindel und ist allein auf eine Änderung in der spektralen Form zurückzuführen (Spur E). Die meisten Zustandsänderungen ziehen einen steilen Anstieg des SFM nach sich (etwa bei den Segmentgrenzen 1, 2 und 3), zumindest in einem der beiden Terme; dementsprechend ist der Wert von Θ nicht besonders kritisch. Wie schon im letzten Abschnitt erläutert, ist der Rauschanteil im zweiten Term, der Änderungen der spektralen Gestalt beschreibt, wesentlich höher als im ersten (Leistungs-) Term. Ein hoher Rauschanteil findet sich insbesondere dann häufig, wenn das Spektrum von einer einzelnen Resonanz dominiert wird (beispielsweise in Segment 6): Dies führt zu einem Prädiktionsfilter relativ hoher Güte, und dementsprechend wird das SFM durch Fluktuationen in der Resonanzfrequenz stark beeinflußt.

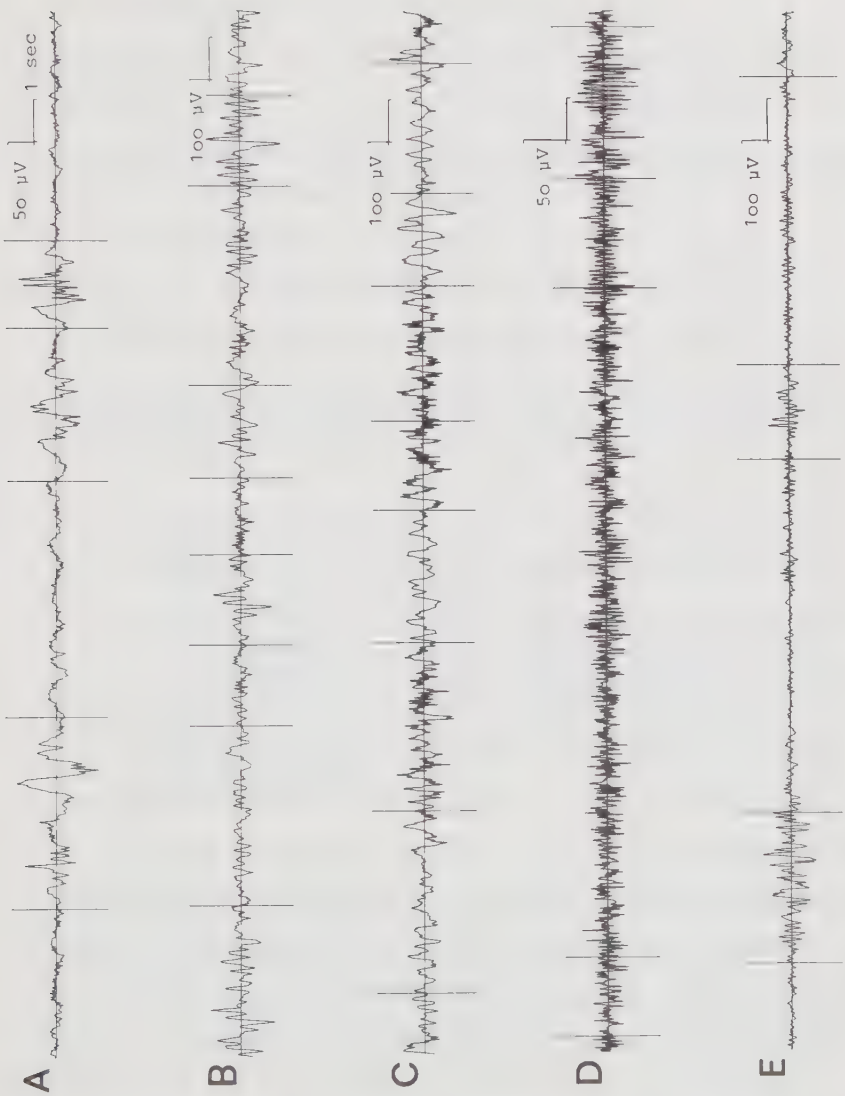

Fig. 9: Beispiele für Segmentation. A: Neugeborenes, normaler Schlaf. B: Kind, 7 Jahre, Schlafstadium I. C: Kind, 8 Jahre, Schlafstadium III. D: Erwachsener, α-EEG. E: Erwachsener, EEG mit Paroxysmen.

Fig. 9 zeigt einige Beispiele für die Segmentation. Wir verwenden vorwiegend Kinder-EEGs, da diese - beim gesunden Kind - mehr Variabilität und damit mehr "Muster" aufweisen als das normale Erwachsenen-EEG. Man beachte, daß in Spur A die Länge der Segmente hoher Signalleistung allgemein überschätzt wird, was darauf zurückzuführen ist, daß die laufende Fehler-AKF zwar empfindlich auf einen einzelnen hohen Wert des PF reagiert (obgleich das durch die Begrenzung sowie die Asymmetrie des SFM reduziert wird), nicht aber auf einen niedrigen Wert. Diese Eigenschaft ist jedoch sehr wünschenswert, da sie bei der Merkmalsgewinnung verhindert, daß Spektren niedriger Leistung durch Komponenten aus benachbarten Segmenten hoher Leistung kontaminiert werden. Die fünfte Segmentgrenze in C und praktisch alle in D sind offenbar "überflüssig": sie sind, wie oben erläutert, auf Fluktuationen des SFM zurückzuführen, die durch scharfe Resonanzen im Signalspektrum erzeugt werden. Solche "überflüssigen" Segmentgrenzen lassen sich jedoch im Anschluß an die Merkmalsgewinnung leicht durch entsprechende Klassifikationsverfahren ("Clustern") wieder beseitigen. Man beachte, daß das längste Segment in D eine Dauer von 16 sec hat, jedoch durch nur 13 Parameter beschrieben wird.

Fig. 10 zeigt die Erkennung von Transienten in zwei kontralateralen Kanälen bei einem epileptischen Patienten. Die Länge der Pfeile ist proportional dem oberhalb des Schwellwertes liegenden Teil der Prädiktionsfehlerleistung und

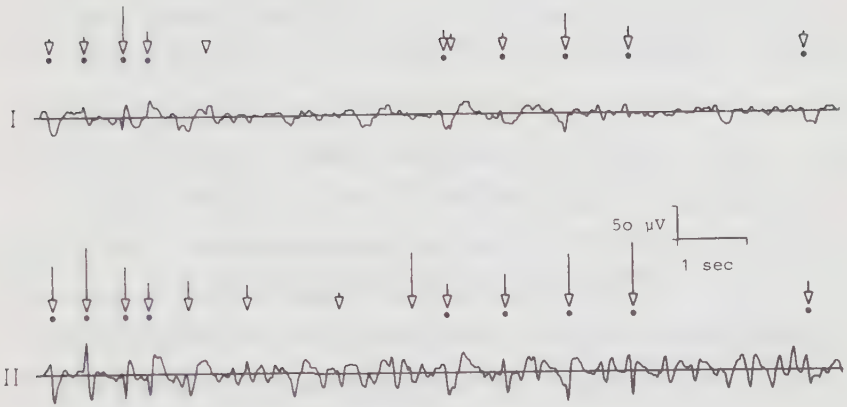

Fig. 10: Erkennung von Transienten. Das von einem epileptischen Patienten abgeleitete inter-iktale EEG weist eine große Zahl von Steilen Wellen auf, insbesondere in Kanal II. Kanäle I und II liegen kontralateral. Simultan in beiden Kanälen erkannte Transienten sind durch Punkte gekennzeichnet. Die Länge der Pfeile entspricht der "Ausgeprägtheit" der Transienten.

liefert somit ein Maß für die "Ausprägung" der Transienten. Wenngleich es schwer ist, "Transienten" (hier: Steile Wellen) exakt zu definieren, zeigt der Vergleich beider Kanäle doch, daß die Methode sinnvolle Ergebnisse liefert: In Kanal II ist die Transientenerkennung relativ problemlos, nicht so aber in Kanal I. Daß die dort markierten Stellen "echt" sind, ergibt sich aus der Synchronie; in beiden Kanälen simultan erkannte Transienten sind durch schwarze Punkte markiert. Die Mustergrenzen sind nicht

eingezeichnet; bei einem so massiven Auftreten von Transienten ist es ohnehin ausreichend, eine grobe Schätzung der unterliegenden Grundaktivität zu erhalten.

Die oben dargestellten Ergebnisse zeigen, daß unser Verfahren es in der Tat gestattet, Elementarmuster aus dem EEG zu isolieren. Damit ist aber noch nicht viel über die Qualität der so gewonnenen Merkmale gesagt. Im Kontext der Mustererkennung muß die Frage lauten: Enthalten die gespeicherten Merkmale die gleiche diagnostische Information über das EEG (also das Muster im weiteren Sinn) wie das Signal selbst?

Die einzige Möglichkeit, diese Frage zu beantworten, ist, sie innerhalb eines diagnostischen Systems zu testen. Anstatt nun ein solches System zu konstruieren, können wir unsere Merkmale ebensogut einem Neurologen präsentieren und ihn fragen, ob er aus ihnen zu den gleichen diagnostischen Schlußfolgerungen gelangt wie anhand des Original-Signals. Natürlich müssen wir die Merkmale in einer für den Menschen geeigneten Form darbieten; hier ist die einfachste Möglichkeit, das Signal, aus dem wir die Merkmale gewonnen haben, aus diesen nachträglich wieder zu simulieren.

Zu diesem Zweck verwenden wir folgendes Verfahren: Innerhalb eines quasi-stationären Segmentes hat der Prädiktionsfehler ein flaches Spektrum. Nun erzeugen wir ein

Signal, indem wir weißes Rauschen entsprechender Leistung mit dem inversen totalen Prädiktor filtern. Falls Transienten erkannt worden sind, werden sie durch Filterung der entsprechenden gespeicherten PF-Werte mit dem inversen Signal-Prädiktor rekonstruiert. Nach Addition beider Signale werden die einzelnen Segmente durch lineare Interpolation innerhalb einer Übergangsperiode von 1 sec miteinander verknüpft. Da wir im Lauf der Simulation einige zusätzliche Annahmen gemacht haben, wird das Ergebnis uns zeigen, was schlimmstenfalls an Information verloren geht.

Fig. 11 zeigt fünf Beispiele einer solchen Simulation; die verwendeten EEGs sind die gleichen wie die in Fig. 9 und 10 gezeigten. Bei jedem EEG-Typ ist die mittlere Datenrate nach der Merkmalsgewinnung angegeben; sie ist umso höher, je mehr Variabilität (entsprechend kurzen Segmenten oder dem Auftauchen von Transienten) das Signal zeigt. Bei der Anwendung in der klinischen Routine können wir einen Wert zwischen 1 und 1,5 Parametern/sec erwarten, was einer Datenreduktion um 1:50 bis 1:30 entspricht. Bei der Betrachtung der simulierten Signale sollte man keine Punkt-zu-Punkt Korrespondenz erwarten; Original und Simulation sollten vielmehr als verschiedene Realisierungen des gleichen stochastischen Prozesses angesehen werden. Auch für den entsprechend ausgebildeten Neurologen scheint es schwierig zu sein, die Signale in Original und Simulation zu unterscheiden (wenngleich das nicht notwendig heißt, daß zwischen ihnen kein Unterschied besteht); leider er-

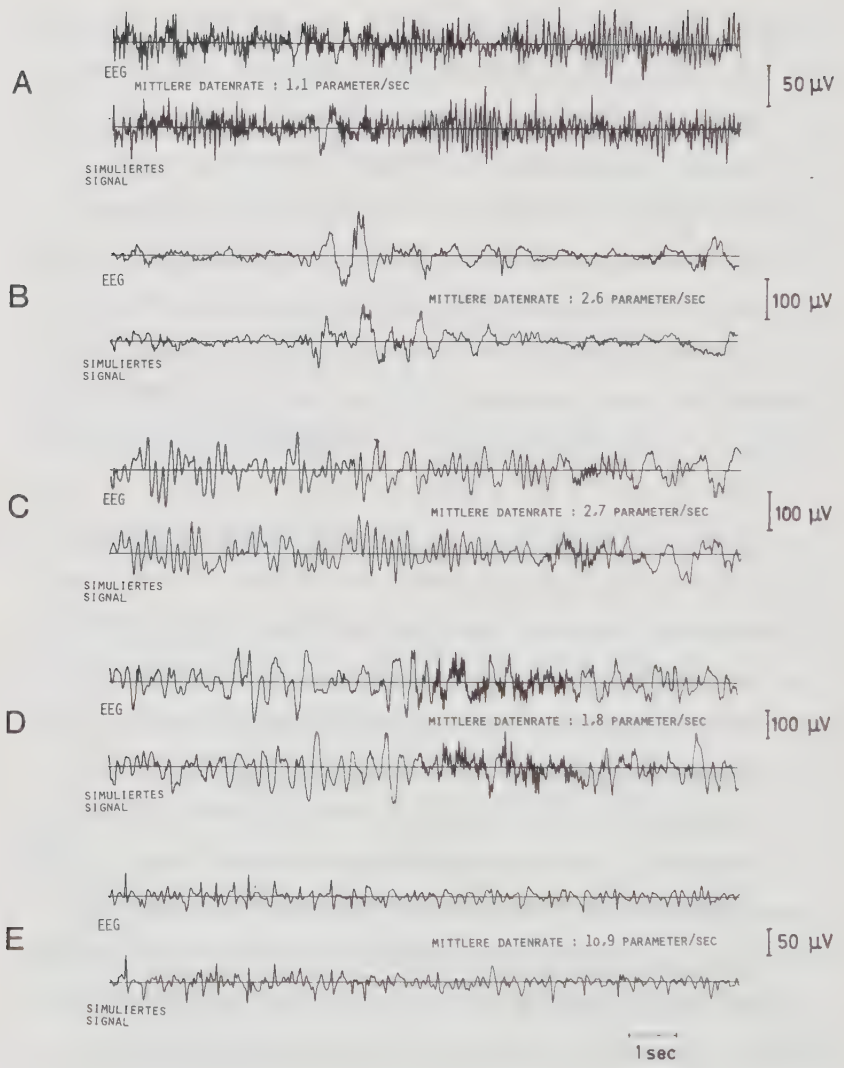

Abb. 11: Original-EEGs und ihre Simulation aus dem gespeicherten Merkmalssatz. A: Wie 9D. B: Wie 9A. C: Wie 9B. D: Wie 9C. E: Wie in 10. Für E wurde zur Demonstration der sehr niedrige Wert $\hat{\theta} = 15\sigma^2$ benutzt, was zu nur geringer Datenreduktion führt.

laubt es die eingeschränkte Menge des verwendeten EEG-Materials nicht, eine solche Schlußfolgerung statistisch zu erhärten.

Von besonderem Interesse ist Fall E, wo eine Vielzahl von Transienten erkannt wird. Abgesehen von ihrer korrekten Rekonstruktion beachte man, daß auch die Struktur der Hintergrundaktivität adäquat wiedergegeben ist, was darauf hindeutet, daß der aus dem Prädiktionsfehler gewonnene Korrekturterm hinreichend den Einfluß der Transienten auf das Signalspektrum eliminiert hat.

10. Erweiterung auf mehrere Kanäle

Sämtliche bisher angestellten Überlegungen bezogen sich auf einen einzelnen Kanal. Nun werden aber bei einer routinemäßigen EEG-Ableitung mindestens 8, typisch 12, häufig gar 16 Kanäle parallel abgeleitet, wobei die Elektroden nach einem bestimmten Schema über den Schädel des Patienten verteilt werden. Diagnostisch wichtig sind nun Seitenvergleiche - also Vergleich der Aktivität in kontralateralen Kanälen - sowie die fokale Verteilung von Paroxysmen, die es gestatten, das Zentrum der pathologischen Aktivität (und damit etwa die Lage eines Tumors) zu bestimmen.

Wenn wir unser Verfahren auf n parallele Kanäle verallgemeinern wollen, so haben wir prinzipiell zwei Möglichkeiten:

(i) Wir fassen die n Kanäle zu einem n-dimensionalen Prozeß zusammen und berechnen dementsprechend auch einen n-dimensionalen Prädiktor; dies gestattet insbesondere auch die Berechnung von Kohärenzen zwischen den einzelnen Kanälen.

(ii) Wir arbeiten einfach simultan mit n eindimensionalen Prädiktoren.

Offenbar ist (i) wesentlich rechenaufwendiger als (ii); weiterhin scheint allgemein Übereinstimmung zu herrschen darüber, daß für klinische Anwendungen Kohärenzen nicht wichtig sind. Daher entscheiden wir uns für (ii) mit

folgender Modifikation: Um sinnvolle Seitenvergleiche zu gewährleisten, ist es wünschenswert, zumindest kontralaterale Kanäle simultan zu segmentieren. Dies läßt sich dadurch erreichen, daß man die individuellen SFM_i zu einem totalen Fehlermaß $SFM_{tot} = f(SFM_1,...,SFM_n)$ kombiniert, wo f symmetrisch für kontralaterale Argumente sein sollte. Fig. 12 zeigt ein Beispiel für eine solche mehrkanalige Segmentation für den einfachen Fall $SFM_{tot} = \Sigma SFM_i$. Das Signal zeigt die für Epilepsie typischen Spike-Wave-Komplexe in den Segmenten 3 und 8. Die Spikes sind durch Pfeile gekennzeichnet. Gerade Spike-Wave-Komplexe werden gern als Beispiel dafür angeführt, es sei notwendig, ein EEG durch Graphoelemente zu beschreiben; in unserem Verfahren dagegen werden sie als "Hybrid" aus quasi-stationärer δ-Aktivität und mit fester Phasenbeziehung überlagerten Transienten angesehen (vgl. Fig. 2F). In Segment 6 erscheint eine auf die rechte Hemisphäre beschränkte Gruppe von δ-Wellen, ein Beispiel für eine diagnostisch relevante Seitenasymmetrie. Der Umstand, daß ihre Länge stark überschätzt wird, ist teilweise auf die schlechte Wahl von f sowie das zu große n zurückzuführen. Die in den Segmenten 7 und 10 erkannten Transienten sind vermutlich Artefakte, die hier aus einer extrem niedervoltigen Grundaktivität herausragen.

Die bisher gewonnenen Erfahrungen auf einem Großrechner (UNIVAC 1108) lassen vermuten, daß sich das soweit dargestellte System zur Echtzeitverarbeitung für zumindest acht parallele Kanäle auf einem kleinen Laborrechner implementieren läßt.

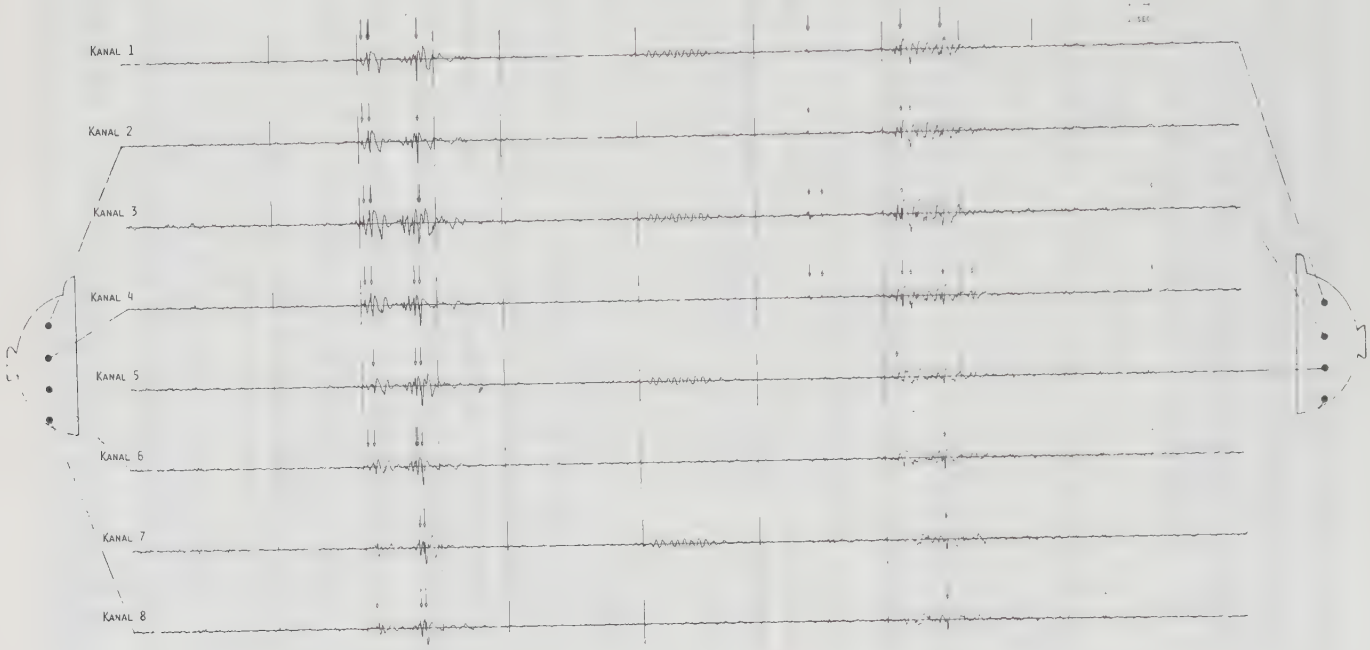

Fig. 12: Simultane Segmentation und Transientenerkennung in acht Kanälen. EEG eines Epileptikers. Segmente 3 und 8: Spike-Wave-Komplexe. Segment 6: Abnorme δ-Wellen, beschränkt auf die rechte Hemisphäre.

11. Perspektiven

Bislang hatten wir uns mit der Gewinnung elementarer Merkmale aus dem EEG beschäftigt. Wir wollen nun im Kontext der Mustererkennung diskutieren, wie sich dieser Merkmalssatz weiter verarbeiten und reduzieren läßt. Wie wir gesehen haben, können wir mit Hilfe des bislang dargestellten Systems zwar auf eine Datenreduktion von maximal 1:50 hoffen; selbst dann jedoch würde eine achtkanalige EEG-Aufzeichnung von 10 min Dauer noch etwa 5000 elementare Merkmale liefern, um einen Faktor 50 mehr, als für gängige Klassifikationsalgorithmen zuträglich ist. Wir müssen die so gewonnenen Daten also weiter reduzieren, und zu diesem Zweck wollen wir uns fragen, ob das EEG noch mehr, bislang nicht verwertete Struktur besitzt, die dann auch im Merkmalssatz noch vorhanden sein müßte.

Der Einfachheit halber schließen wir Transienten von den folgenden Betrachtungen aus, beschränken uns also auf quasi-stationäre Segmente. Nachdem wir eine geeignete Zustandsbeschreibung des EEG gefunden haben - in unserem Fall, entsprechend Hypothese II, Leistungspektren -, können wir das EEG als Trajektorie X(t) in dem entspreche den Zustandsraum darstellen. Hypothese I besagt dann, daß X(t) relativ lange in der Nähe gewisser Punkte (die die Segmente repräsentieren) bleiben wird (entsprechend den "Knoten" in Fig. 13, links), um dann plötzlich zum

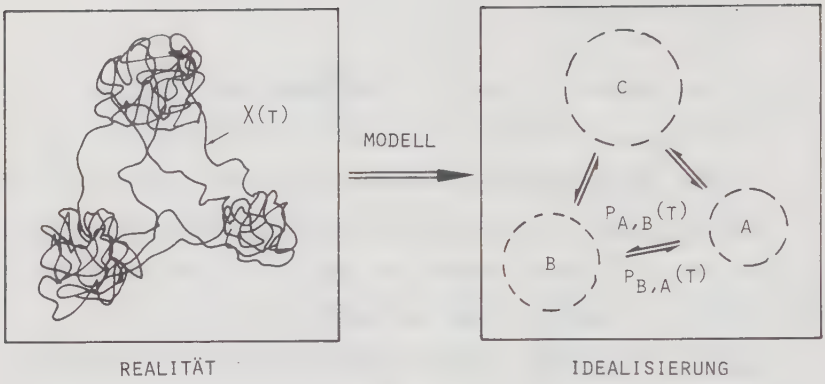

Fig. 13: Repräsentation des verwendeten phänomenologischen Modells. Die Quadrate stellen einen zweidimensionalen Zustandsraum dar. In der Realität (links) entspricht der Signaltrajektorie X(t) eine stetige Kurve mit "Knoten", die als ein System metastabiler Zustände idealisiert werden (A, B, C; rechts). Der resultierende Prozeß ist vermutlich stationär; falls er darüber hinaus ein Markoff-Prozeß ist, kann er durch feste Übergangswahrscheinlichkeiten (etwa $p_{A,B}(t)$) vollständig beschrieben werden.

nächsten zu wandern. Diese Situation ist in Fig. 13 links dargestellt, rechts ihre Idealisierung. Dies war demnach eine Annahme über die Existenz metastabiler Zustände, doch wurde bislang nichts über ihre Eigenschaften gesagt. Wir erweitern nun unser Modell um

Hypothese III (Zustandsstruktur):

Das EEG besteht aus einer endlichen Zahl rekurrenter Zustände.

Natürlich müssen wir mit einem gewissen Zustandsrauschen

rechnen, das durch die gestrichelten Kreise in Fig. 13 angedeutet ist, wo insgesamt drei Zustände gezeigt sind; wir nehmen lediglich an, daß die Segmente in voneinander gut trennbare Haufen("Cluster") zerfallen, deren einzelne Elemente für das menschliche Auge ähnlich sind. Beispiele hierfür lassen sich in Fig. 9 finden: Wir sehen intuitiv zwei Zustände in A, drei in B, zwei in C, nur einen in D, und zwei in E. Natürlich wird dies nicht gelten in Fällen, in denen sich die biochemischen Verhältnisse im Gehirn kontinuierlich ändern, etwa direkt nach der Einnahme gewisser Medikamente oder nach dem Beginn einer Hyperventilation; wir beschränken uns auf routinemäßige Ableitungen ohne Provokationsmethoden.

Hypothese III führt zu folgender Konsequenz: Anstatt zu versuchen, die einzelnen Segmente direkt (diagnostisch) zu klassifizieren, sollten wir zunächst die diskreten Zustände auffinden. Dies aber ist - ohne zusätzliche Information - leicht möglich durch die Verwendung von Cluster-Prozeduren: Diese werden ähnliche Segmente zusammenfassen und zugleich alle "überflüssigen" Segmentgrenzen beseitigen. Fig. 14 zeigt ein Beispiel: Das EEG wird in zwei Zustände aufgespalten, ihre Elemente sind links gezeigt; rechts die Simulation der Schwerpunkte beider Zustände. Auf diese Weise läßt sich bei n Zuständen ihre Struktur beschreiben durch $n(p+M+1)$, in diesem Fall 24, Parameter, und es verbleibt lediglich die Zeitstruktur, die nur einen Parameter pro Segment

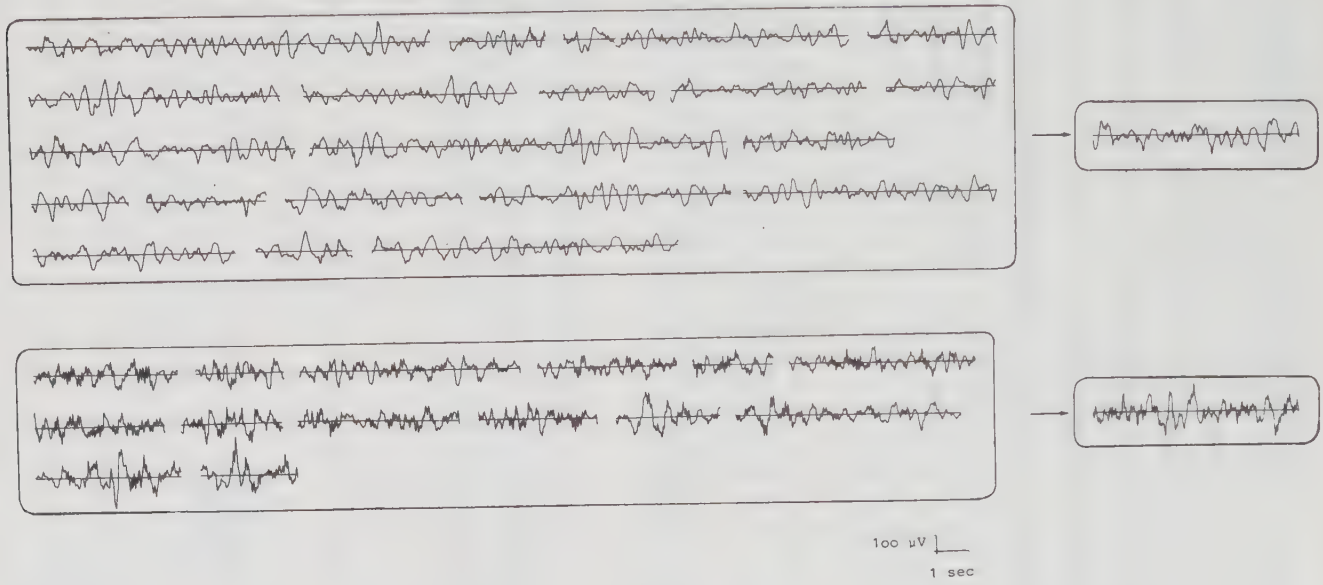

Fig. 14: "Cluster" von Merkmalssätzen, die aus einem EEG des in Fig. 9C gezeigten Typs gewonnen wurden. Cluster-Algorithmus nach Ward [31]. Die gezeigte Aufspaltung ist stabil innerhalb mehr als 50% des Gesamtbereichs der Summe der Fehlerquadrate. Links die einzelnen Signalsegmente, rechts Simulationen der entsprechenden Schwerpunkte. (Aus [25]).

erfordert. Falls man zusätzlich - in dieser Zustandsbeschreibung - das EEG durch einen Markoff-Prozeß approximiert, so läßt sich die - vermutlich stationäre - Zeitstruktur durch die verschiedenen Übergangswahrscheinlichkeiten $p_{n,m}(t)$ beschreiben, wie in Fig. 13 dargestellt ist. Diese Übergangswahrscheinlichkeiten wiederum können durch einige wenige - etwa 2 - Parameter repräsentiert werden; dies würde dann einen endgültigen Merkmalssatz ergeben, der unabhängig ist von der Länge des ursprünglichen Signals und dessen Dimension unter 100 liegen dürfte. Man beachte, daß sich dieser dritte Teil im Anschluß an die Echtzeitverarbeitung ausführen läßt; der elementare Merkmalssatz ist klein genug, um in einem schnellen Speichermedium gehalten zu werden.

Zum Schluß wollen wir nochmals zu Fig. 1 zurückkehren, wo wir das Problem der EEG-Diagnose aufgeteilt hatten in Merkmalsgewinnung und Klassifikation. So betrachtet, gehör der Schritt der Zusammenfassung der Segmente zu "Clustern" eigentlich nicht zum Klassifikationsteil; vielmehr ist seine Aufgabe, die anfänglich vorgenommene Aufspaltung rückgängig zu machen, wie in Fig. 15 dargestellt ist: In einem ersten Schritt hatten wir das Grundmuster (EEG) in Elementare Muster entsprechend Hypothese I aufgespalten Hypothese II sagt uns dann, welche Elementaren Merkmale wir aus ihnen gewinnen sollten. Schließlich fassen wir in einem dritten Schritt diese zu einem endgültigen Merkmalssatz zusammen, wozu wir entsprechend Hypothese III Cluster

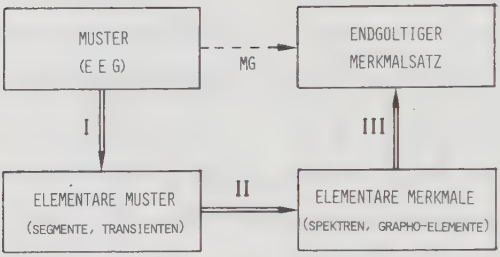

Fig. 15: Schema der Merkmalsgewinnung aus dem EEG.
----→ : "Direkte" Merkmalsgewinnung, hier nicht möglich infolge der komplexen Struktur des Signals.
⟹ : Vorgeschlagener Weg der Merkmalsgewinnung.
I: Aufteilung in Elementare Muster (Hypothese I)
II: Gewinnung elementarer Merkmale (Hypothese II)
III: Reduktion der elementaren Merkmale zum endgültigen Merkmalssatz (Hypothese III).

Prozeduren verwenden. Erst dies ist die Stufe, wo wir diese Daten mit zusätzlicher klinischer Information kombinieren können, um darauf Prozeduren zur diagnostischen Klassifikation anzuwenden.

TEIL B: EVOZIERTE PHÄNOMENE

MODULATIONSTRANSFER IM AKUSTISCHEN SYSTEM

12. Stimuli und Observable

Schon seit langer Zeit versucht man, der Signalverarbeitung innerhalb des akustischen Systems im Gehirn (und ihren Störungen) auf die Spur zu kommen. Abgesehen von rein anatomischen Studien geht man dazu so vor, daß man dem Versuchsobjekt - sei es ein Tier, eine Versuchsperson oder ein Patient - ein Signal, den Reiz oder Stimulus, präsentiert und dann eine Observable mißt: in der Psychophysik zumeist eine logische ("hören Sie diesen Ton?"), weiter analoge (akustisch evozierte Potentiale auf der Kopfhaut oder, im Tierversuch, Massenpotentiale auf dem und im Cortex) und schließlich mit Mikroelektroden Einzelzellenentladungen.

So qualitativ eingeschränkt auch die Zahl der Observablen ist, umso größer ist die Freiheit, die bei der Auswahl der Stimuli besteht. Beschränken wir uns auf den Fall, daß die gemessene Größe eine Form elektrischer Hirnaktivität ist: Hier finden wir durchgängig einen hohen Gehalt an Störungen ("Rauschen"), und die Befreiung davon wird gängigerweise dadurch erreicht, daß ein bestimmter Reiz repetitiv dargeboten und anschließend über den zeitlichen Verlauf der einzelnen Antworten gemittelt wird: Dies resultiert bei Massenpotentialen im sogenannten

"Evozierten Potential", bei Einzelzellableitungen erhält man das "Post-Stimulus Time Histogram" (PSTH). Die am häufigsten verwendeten Stimuli lassen sich - sehr grob - in die Klassen Amplitudenmodulation, Frequenzmodulation, natürliche Laute einteilen.

In diesem Zusammenhang ist der Umstand zu bedenken, daß an allgemeinen Verarbeitungsprinzipien innerhalb des akustischen Systems* - verglichen etwa mit dem Ohr - nur relativ wenig bekannt ist. Welche Merkmale etwa aus dem Signal extrahiert werden, ist immer noch eine große Frage.

Betrachten wir nun den Raum aller akustischen Stimuli; welche Aussagen können wir über ihn machen? Wenn wir ihn zunächst alle Stimuli enthalten lassen, die überhaupt hörbar sind, müssen wir alle Funktionen endlicher Energie mit einer oberen Grenzfrequenz, die etwa beim Menschen bei 18 kHz liegt, zulassen. Dieser Raum ist sicherlich zu groß, um uns von Nutzen zu sein, doch läßt er sich wesentlich mehr Struktur geben. Uns kommt hier die folgende Eigenschaft der meisten natürlichen akustischen Reize zugute (auf der auch das Prinzip des Spektrogramms und der "VoCoder" [28] beruht): Viele Signale - bestes Beispiel ist Sprache - lassen sich aufspalten in einen schnell

---

* Unter "akustischem System" wollen wir im Rahmen dieser Arbeit lediglich die Strukturen verstehen, die zwischen Cochlea und Cortex liegen.

veränderlichen, quasi-periodischen Teil - wir wollen ihn "Träger" nennen - und einen langsam veränderlichen Teil (beispielsweise ein Leistungsspektrum, das dann der Einhüllenden des Signalspektrums entspricht). Wir können dann versuchen, diesen "langsamen" Teil durch eine kleine Zahl von Parametern - sagen wir, zehn - darzustellen, wo man für diese Parameter eine Bandbreite unter 50 Hz annehmen darf. Auf diese Weise erhalten wir also eine erhebliche Reduktion des Stimulusraums.

In diesem Zusammenhang sei bemerkt, daß auch der akustische Cortex sich eine entsprechende Eigenschaft zunutze machen muß: der Cortex kann - aus uns nicht bekannten Gründen - nur "langsame" Signale verarbeiten, und entsprechende Merkmale müssen daher aus dem ursprünglichen Signal zunächst gewonnen werden. In diesem Sinn ist das erwünschte Endziel einer solchen Aufspaltung in "schnelle" und "langsame" Komponenten, eine eindeutige Beziehung zwischen langsamen Parametern und den innerhalb des akustischen Systems gewonnenen Merkmalen herzustellen; dies wäre dann die optimale Repräsentation des Stimulusraums. Solange wir diese Zusammenhänge nicht kennen, sind wir darauf angewiesen, mit uns aus verschiedenen Gründen wichtig erscheinenden Parametern zu beginnen.

Leider gelingt es zur Zeit noch nicht, allgemein gültige Aussagen über die Struktur der langsamen Parameter selbst zu machen. Unter diesen Umständen fehlender a-priori

Information erscheint es sinnvoll, den Reiz so zu wählen, daß er - genügend Zeit gegeben - möglichst große Bereiche des (reduzierten) Stimulusraums überstreicht. Dies ist gerade die Klasse der ergodischen Reize: Ein bekanntes Beispiel ist Gauß'sches weißes (in unserem Fall bei maximal 50 Hz bandbeschränktes) Rauschen, in dem - bei hinreichender Dauer - alle nur denkbaren Stimuli enthalten sind. Wenn wir also einen oder auch mehrere der langsamen Parameter durch Rauschen der entsprechenden Bandbreite ersetzen, können wir hoffen, damit einen relativ großen, "sinnvollen" Bereich des Raums abzudecken; man beachte den Unterschied etwa zu Breitbandrauschen von 20 Hz bis 20 kHz, wo das Verhältnis zwischen "sinnlosem" und "sinnvollem" Signalanteil zu groß wäre.

Beschäftigen wir uns nun mit dem zweiten Problem, nämlich der Wahl der Observablen. Das an der Kopfhaut abgeleitete akustisch evozierte Potential ist zwar in Klinik und Psychophysik - mangels anderer nicht-invasiver Verfahren - weit verbreitet, doch sind die hier meßbaren Potentialschwankungen durch andere Hirnaktivitäten, insbesondere den alpha-Rhythmus, stark kontaminiert. Bei Versuchstieren dagegen besteht die Möglichkeit, nach Öffnung des Schädels kortikale und intrakortikale Potentiale abzuleiten, die wesentlich störungsfreier sind und einen Überblick über die synchrone Aktivität innerhalb eines kleinen, gut lokalisierten Gebietes (Größe unter $1mm^3$) geben. Bei ihrer Interpretation muß man sich allerdings

zweier Schwierigkeiten bewußt sein: Zunächst einmal kennt man - wie beim EEG - nicht die genaue Entstehungsweise dieser Potentiale; vermutlich werden sie durch Überlagerung post-synaptischer Potentiale generiert [4]. Wir halten jedenfalls fest, daß sie eher "Abfallprodukte" der Hirnaktivität sind. Das zweite Problem hängt zusammen mit der Frage der Homogenität des Cortex: So klein das untersuchte Gebiet auch ist, es enthält doch Hunderte von Zellen und wird von Tausenden von Fasern durchzogen. Falls darunter nun verschiedene Zelltypen mit verschiedenen Funktionen sind - und das muß man annehmen -, dann wird das intrakortikale Potential die Summe ihrer Aktivitäten aufzeigen. Erst auf dem Niveau der Einzelzellableitung, wo diskrete Zellentladungen registriert werden, messen wir die Funktion des Systems, für die es angelegt ist. Zwar haben wir es dann anstatt mit Analogsignalen mit Punktprozessen zu tun, doch ist dies keine prinzipielle Schwierigkeit. Schwerer wiegt, daß wir eine einzelne Zelle nicht als repräsentativ für das untersuchte Cortexareal ansehen dürfen. Da dieses Problem durch die Verwendung von Massenpotentialen vermieden wird, wurden diese als Observable gewählt. Die vorliegende Untersuchung sollte daher als vorläufig und methodischer Natur angesehen werden; wir müssen die Schwierigkeiten bei der Interpretation von Massenpotentialen im Auge behalten und vermerken, daß eine Überprüfung von so gebildeten Hypothesen immer auf dem Niveau der Einzelzelle erfolgen muß.

Nachdem Stimulus und Observable prinzipiell ausgewählt sind,

bleibt die Frage, welches Modell wir für unsere Systemanalyse benutzen wollen. Da die vorhandene a-priori Information gering ist, müssen wir auf die Verwendung eines strukturellen Modells verzichten. In dieser Situation bietet sich die Verwendung eines "funktionalen Modells" [21] an: Wir bestimmen durch ein Experiment die Funktionale, die - entsprechend einem gewissen Gütekriterium - in optimaler Weise den durch den Reiz überdeckten Teil des Stimulus-Raums in den Raum der Observablen abbilden. Hierbei stellen wir die folgenden Bedingungen:

- Wir müssen im Auge behalten, daß lineare Systeme nur eine - bei biologischen Systemen im Gegensatz zur Physik sehr kleine - Untermenge aller (nichtlinearen) Systeme bilden. Dies verbietet lineare Approximation als Ausgangspunkt einer solchen Untersuchung.

- Biologische Systeme sind stark verrauscht. Wir müssen daher eine Methode finden, in der Rauschen zumindest keine prinzipiellen Schwierigkeiten für die Bestimmung des Modells mit sich bringt.

Im folgenden Abschnitt beschreiben wir die Wiener-Volterra-Methode, die diesen beiden Forderungen Rechnung trägt.

13. Die Wiener-Volterra-Entwicklung*

Ein lineares, zeitinvariantes System läßt sich beschreiben durch seine Impulsantwort $H(t)$, und zwar sind Eingang, $x(t)$, und Ausgang, $y(t)$, des Systems verknüpft durch die lineare Transformation

$$y(t) = \int H(\tau)x(t-\tau)d\tau \tag{13.1}$$

In seiner Analyse nichtlinearer Systeme [34] nahm N. Wiener diese Beziehung zum Ausgangspunkt einer allgemeineren Entwicklung, die ein nichtlineares System als Summe einer aufsteigenden Folge von multiplikativen Wechselwirkungen beschreibt nach dem Schema

$$\begin{aligned} y(t) = {} & K_o \\ & + \int K_1(\tau_1)x(t-\tau_1)d\tau_1 \\ & + \int K_2(\tau_1,\tau_2)x(t-\tau_1)x(t-\tau_2)d\tau_1 d\tau_2 \\ & + \int K_3(\tau_1,\tau_2,\tau_3)x(t-\tau_1)x(t-\tau_2)x(t-\tau_3)d\tau_1 d\tau_2 d\tau_3 \\ & + \ldots\ldots \end{aligned} \tag{13.2}$$

oder allgemein

$$y(t) = \sum_{n=o}^{\infty} \int K_n(\tau_1,\ldots,\tau_n) \prod_{m=1}^{n} x(t-\tau_m)d\tau_m \tag{13.3}$$

---

* Für eine ausführliche Darstellung verschiedener Anwendungen dieser Methode auf biologische Systeme siehe [22].

Man bezeichnet $K_n(\tau_1,\ldots,\tau_n)$ als Volterra-Kern n-ter Ordnung. Die obige Entwicklung wird häufig als "Reihe mit Gedächtnis" bezeichnet: Im Fall einer Nichtlinearität ohne Gedächtnis reduziert sie sich auf eine Taylor-Entwicklung, im Fall eines linearen Systems auf die Darstellung (13.1). Die Klasse aller Funktionale, die sich so darstellen lassen, ist bislang leider nicht bekannt; dieses Problem ist in [3,6] diskutiert.

Im folgenden beschränken wir uns auf den Fall, daß das Eingangssignal x(t) Gauß'sches weißes Rauschen der Leistung P ist. Bei verschwindendem Mittelwert ist die Statistik des Prozesses damit festgelegt: Alle ungeraden Momente des Eingangssignals verschwinden, und die geraden lassen sich darstellen als Produkte aus δ-Funktionen, insbesondere

$$\langle x(\tau_1)x(\tau_2)\rangle = P\delta(\tau_1-\tau_2)$$

$$\langle x(\tau_1)x(\tau_2)x(\tau_3)x(\tau_4)\rangle = P^2\{\delta(\tau_1-\tau_2)\delta(\tau_3-\tau_4)+\delta(\tau_1-\tau_3)\delta(\tau_2-\tau_4)+$$
$$+\delta(\tau_1-\tau_4)\delta(\tau_2-\tau_3)\} \qquad (13.4)$$

Da x(t) ergodisch ist, können wir allgemein Scharmittel durch Zeitmittel (angedeutet durch Überstreichen) ersetzen.

Wir können nun die Reihenentwicklung (13.2) bezüglich dieses Eingangssignals orthogonalisieren [34]; dies resultiert in einer aufsteigenden Folge von Funktionalen $G_n: f \mapsto g_n$ (wo $f: t \mapsto x(t)$, $\Sigma g_n = g$, $g: t \mapsto y(t)$), wobei $\langle g_n, g_m\rangle = 0$ für $n \neq m$ gilt. Wir benutzen der Einfachheit halber die Bezeichnung x(t) für f;

die ersten vier so entstehenden Terme sind

$$G_o(K_o;x(t)) = K_o$$

$$G_1(K_1;x(t)) = \int K_1(\tau_1)x(t-\tau_1)d\tau_1$$

$$G_2(K_2;x(t)) = \int K_2(\tau_1,\tau_2)x(t-\tau_1)x(t-\tau_2)d\tau_1 d\tau_2 - P\int K_2(\tau,\tau)d\tau$$

$$G_3(K_3;x(t)) = \int K_3(\tau_1,\tau_2,\tau_3)x(t-\tau_1)x(t-\tau_2)x(t-\tau_3)d\tau_1 d\tau_2 d\tau_3 - 3P\int K_3(\tau_1,\tau,\tau)x(t-\tau_1)d\tau d\tau_1 \qquad (13.5)$$

.....

und es gilt

$$\overline{G_m(K_m;x(t))G_n(K_n;x(t))} = o \text{ für } m \neq n \qquad (13.6)$$

Dies bedeutet, daß wir bei Abbruch der Reihenentwicklung (13.5) bei einem bestimmten Grad n die im Sinne eines quadratischen Fehlerkriteriums beste Approximation an das tatsächliche System erhalten. Weiterhin gestatten es uns die Orthogonalitätsbeziehungen (13.6), die verschiedenen Kerne - bei Stimulation mit Gauß'schem weißen Rauschen - auf einfache Weise zu bestimmen [16]: Man kann zeigen, daß das Funktional n-ter Ordnung, G_n, lediglich vom Kern K_n abhängt, wie schon in (13.5) angedeutet ist. Das aber bedeutet, daß G_n orthogonal ist zu beliebigen Funktionalen niedrigerer Ordnung, insbesondere auch zu

$$X_m(x(t)) = x(t+\tau_1)\cdot\ldots\cdot x(t+\tau_m) \qquad (13.7)$$

Wir wollen im folgenden zur Vereinfachung der Formeln voraussetzen, daß bei fehlendem Eingangssignal der Systemausgang verschwindet, also $K_o=o$ gilt. Wir merken weiter an, daß wir ohne Einschränkung der Allgemeinheit alle Kerne als total symmetrisch voraussetzen dürfen; andernfalls könnten wir sie symmetrisieren, was am Ausgangssignal und damit der Observablen nichts ändert.

Der Kern 1. Ordnung berechnet sich aus der Kreuzkorrelation zwischen Eingang und Ausgang: Es ist

$$\begin{aligned}\overline{y(t)x(t+\tau)} &= \sum_{n=o}^{\infty} \overline{G_n(K_n;\vec{x(t)})x(t+\tau)} \\ &= K_o\overline{x(t+\tau)} + \overline{G_1(K_1;x(t))x(t+\tau)} \\ &= \int K_1(\sigma_1)\overline{x(t-\sigma_1)x(t+\tau)}d\sigma_1 \\ &= P\int K_1(\sigma_1)\delta(\sigma_1+\tau)d\sigma_1 \\ &= PK_1(-\tau) \qquad (13.8)\end{aligned}$$

oder

$$K_1(\tau_1) = \frac{1}{P}\overline{y(t)x(t-\tau_1)} \qquad (13.9)$$

Entsprechend ergibt sich der Kern 2. Ordnung aus

$$\begin{aligned}&\overline{y(t)x(t+\tau_1)x(t+\tau_2)} \\ &\quad = K_o\overline{x(t+\tau_1)x(t+\tau_2)} \\ &\quad + \int K_1(\sigma_1)\overline{x(t-\sigma_1)x(t+\tau_1)x(t+\tau_1)}d\sigma_1 \\ &\quad + \int K_2(\sigma_1,\sigma_2)\overline{x(t-\sigma_1)x(t-\sigma_2)x(t+\tau_1)x(t+\tau_2)}d\sigma_1 d\sigma_2 \\ &\quad - P\int K_2(\sigma,\sigma)d\sigma\overline{x(t+\tau_1)x(t+\tau_2)} \\ &= P^2\{\int K_2(\sigma_1,\sigma_2)\{\delta(\sigma_1-\sigma_2)\delta(\tau_1-\tau_2)+\delta(\sigma_1+\tau_1)\delta(\sigma_2+\tau_2) \\ &+\delta(\sigma_1+\tau_2)\delta(\sigma_2+\tau_1)\}d\sigma_1 d\sigma_2 - \int K_2(\sigma,\sigma)d\sigma\delta(\tau_1-\tau_2)\} \\ &\quad = 2P^2K_2(-\tau_1,-\tau_2) \qquad (13.10)\end{aligned}$$

oder

$$K_2(\tau_1,\tau_2) = \frac{1}{2P^2}\,\overline{y(t)x(t-\tau_1)x(t-\tau_2)} \tag{13.11}$$

Auf diese Weise fährt man fort; wir geben noch den Kern 3. Ordnung an: Es ist

$$K_3(\tau_1,\tau_2,\tau_3) = \frac{1}{6P^3}\,\overline{y(t)x(t-\tau_1)x(t-\tau_2)x(t-\tau_3)}$$

$$\text{für } \tau_1\neq\tau_2\neq\tau_3 \tag{13.12}$$

Wir wollen nun untersuchen, welchen Einfluß es auf die Kerne hat, wenn vor oder hinter das untersuchte System ein lineares System geschaltet wird [30]. Sei also $\hat{\Sigma}$ das System, das sich ergibt, wenn vor das System Σ ein lineares System mit der Impulsantwort $H(t)$ gesetzt wird. Dies resultiert in einem Ausgangssignal

$$\begin{aligned}\hat{y}(t) &= \sum_{n=1}^{\infty} \int K_n(\sigma_1,\ldots,\sigma_n) \prod_{m=1}^{n} H(t-\sigma_m-\tau_m)x(\tau_m)\,d\sigma_m d\tau_m \\ &= \sum_{n=1}^{\infty} \int \{K_n(\sigma_1,\ldots,\sigma_n) \prod_{m=1}^{n} H(t-\tau_m-\sigma_m)\,d\sigma_m\} \prod_{m=1}^{n} x(\tau_m)\,d\tau_m\end{aligned} \tag{13.13}$$

und der neue Kern n-ter Ordnung ist

$$\hat{K}_n(\tau_1,\ldots,\tau_n) = \int K_n(\sigma_1,\ldots,\sigma_n)H(\tau_1-\sigma_1)\ldots H(\tau_n-\sigma_n)\,d\sigma_1\ldots d\sigma_n \tag{13.14}$$

also eine n-dimensionale Faltung des ursprünglichen Kerns mit dem linearen Filter. Für ein kausales $H(t)$ bedeutet das, daß jeder Punkt des Kerns $K_2(\tau_1,\tau_2)$ in einem kausalen

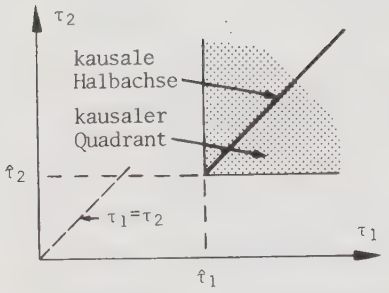

Fig. 16: Ausschmierung eines Punktes im Kern 2. Ordnung $(\hat{\tau}_1,\hat{\tau}_2)$, wenn ein lineares System vor (kausaler Quadrant) oder hinter (kausale Halbachse) das untersuchte System geschaltet wird.

Quadranten ausgeschmiert wird (Fig. 16). Dies illustriert zugleich die allgemeine Eigenschaft der Kerne, daß in jedem die Kausalität erhalten bleibt [6].

Für den Fall, daß das lineare System hinter Σ geschaltet wird, erhalten wir eine noch einfachere Relation, was darauf zurückzuführen ist, daß das Gedächtnis von H hier nicht mehr zur Wechselwirkung beitragen kann. Analog zu (13.13) erhält man

$$K_n(\tau_1,\ldots,\tau_n) = \int \hat{K}_n(\tau_1-\sigma,\ldots,\tau_n-\sigma)H(\sigma)d\sigma \qquad (13.15)$$

Somit wird hier jeder Punkt entlang einer kausalen Halbachse parallel zur Diagnonalen $\tau_1=\tau_2$ ausgeschmiert (Fig. 16).

Wir haben bislang stillschweigend vorausgesetzt, daß uns weißes Rauschen zur Verfügung steht. Dies kann aber immer nur angenähert der Fall sein, und wir wollen nun untersuchen, welchen Einfluß die Verwendung von bandbegrenztem Rauschen hat [16]. Sei also nun $\hat{x}(t)$ ein Gauß'scher Prozeß

mit dem Leistungsspektrum $P(\omega)$. Wir wollen voraussetzen, daß sich P faktorisieren läßt in

$$P(\omega) = A(\omega)A^*(\omega) \tag{13.16}$$

derart, daß $A(\omega)$ ein minimalphasiges System repräsentiert*. Dann ist auch $A^{-1}(\omega)$ minimalphasig, und beide Filter sind insbesondere - bei beschränktem Frequenzband, was bei uns ja der Fall sein wird - realisierbar. Der (gedachte) Prozeß $x(t) = (A^{-1}\hat{x})(t)$, der durch Filterung von $\hat{x}$ mit A^{-1} entsteht, ist nun Gauß'sches weißes Rauschen. Andererseits ist das ursprüngliche System, Σ, nun ersetzt durch das System $\hat{\Sigma}$, das durch Vorschalten des linearen Systems mit der Transferfunktion $A(\omega)$ entsteht (siehe Fig. 17).

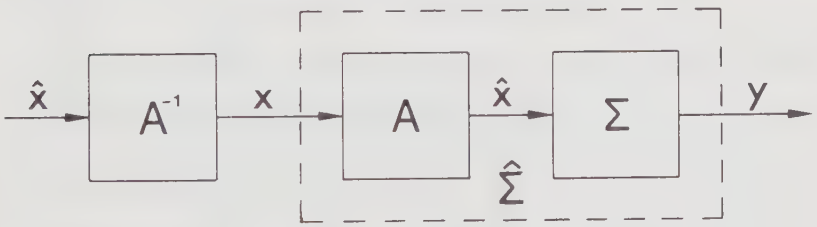

Fig. 17: Äquivalenz zwischen dem interessierenden System Σ, das nur mit bandbeschränkten Signalen getestet werden kann, und dem hypothetischen System $\hat{\Sigma}$, dessen Eingangssignal, x, weißes Rauschen ist.

---

* Das ist exakt nur dann möglich, wenn $P(\omega)$ das Paley-Wiener-Kriterium erfüllt (im diskreten Fall muß $\int \log P(\omega) d\omega$ existieren).

Wir können nun die Ergebnisse der vorangehenden Bemerkungen verwenden und sehen so, daß sich die gewünschten Kerne $\hat{K}_n$ durch multidimensionale Dekonvolvierung der (tatsächlich meßbaren) Kerne K_n mit der inversen Fouriertransformierten von $A(\omega)$ errechnen lassen.

Bislang haben wir mit kontinuierlichen Signalen gearbeitet. In der Praxis geht man so vor, daß Ein- und Ausgangssignal zu diskreten Zeiten mit der Rate ν abgetastet und dann auf einem Digitalrechner verarbeitet werden. Wir haben also eine Eingangsfolge $\{x(i)\}$ und eine Ausgangsfolge $\{y(i)\}$. Alle Momente des Eingangssignals werden so singularitätenfrei, also etwa ($<...>$ bezeichnet Summation über Index i)

$$<x(i)x(i+k)> = P\delta_{o,k} \tag{13.17}$$

Dies hat den Vorzug, daß alle Kerne auch bei mehreren identischen Argumenten direkt meßbar durch multidimensionale Kreuzkorrelation werden. Insbesondere ist

$$K_1(k) = \frac{1}{P} <y(i)x(i-k)>$$

$$K_2(k,l) = \frac{1}{2P^2} <y(i)x(i-k)x(i-l)>$$

$$K_3(k,l,m) = \frac{1}{6P^3} <y(i)x(i-k)x(i-l)x(i-m)>$$

$$- \frac{1}{6P} \{K_1(k)\delta_{l,m}+K_1(l)\delta_{k,m}+K_1(m)\delta_{k,l}\} \tag{13.18}$$

.....

Wir wollen nun abschätzen, wie groß der Zeitbedarf für die Bestimmung der Kerne ist. Seien Ein- und Ausgangssignal der zeitlichen Dauer T gegeben, und sei das Systemgedächtnis geringer als μ. Wir müssen die Kerne also für Argumente $o<\tau<\mu$ bestimmen. Sei $N=T\cdot\nu$ die resultierende Zahl von Datenpunkten und $M=\mu\cdot\nu$ die der zu berechnenden Argumente pro Dimension. Für die Kreuzkorrelation n-ter Ordnung ergibt sich für die Anzahl der benötigten Multiplikationen der Wert $N\cdot M^n/n! = T\cdot\mu^n\cdot\nu^{n+1}/n!$ (der Quotient n! resultiert aus der Symmetrie der Kerne). Man beachte, daß schon beim Kern 2. Ordnung - also dem ersten Wechselwirkungsterm - der Zeitbedarf kubisch mit der Abtastrate steigt.

Fassen wir die Ergebnisse dieses Abschnitts zusammen: Die Wiener-Volterra-Reihe ist eine Entwicklung, die es gestattet, ein (fast) beliebiges System ohne a-priori Kenntnis zu analysieren. Der Kern n-ter Ordnung läßt sich interpretieren als die (nicht notwendig strukturell existierende) Systemkomponente, die nach Aufspaltung und den Argumenten entsprechender Verzögerung des Eingangssignals dieses mit sich selbst multiplikativ wechselwirken läßt. Wir müssen gerade bei biologischen Systemen mit einem hohen Anteil an Rauschen rechnen, worunter wir solche Signalanteile verstehen wollen, die statistisch unabhängig vom Eingangssignal sind; die Messung der Kerne durch multidimensionale Kreuzkorrelation eliminiert gerade solche Anteile, die lediglich den Effekt einer Verlangsamung der Konvergenz der Kernschätzungen haben.

14. Akustisches System und Modulationstransfer

In diesem Abschnitt wollen wir den zu verwendenden Stimulus definieren und geben zugleich eine kurze Darstellung der uns interessierenden Eigenschaften des akustischen

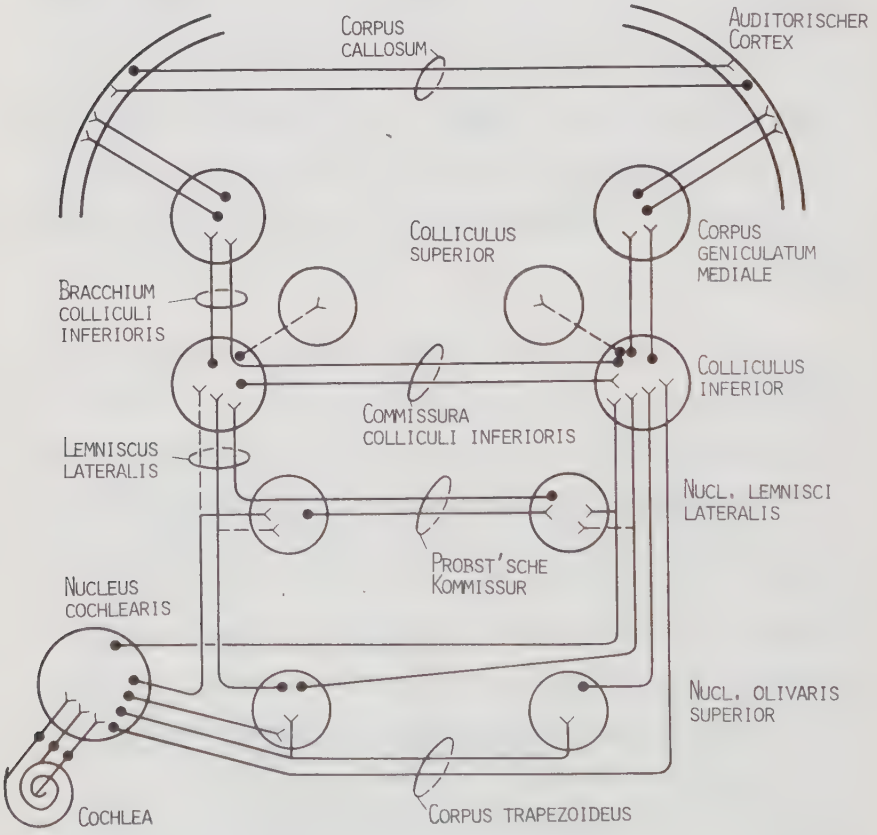

Fig. 18: Diagramm der wichtigsten Subsysteme und Verbindungen im aufsteigenden (afferenten) akustischen System. Gestrichelt gezeichnete Verbindungen sind nicht gesichert. Nur die von der linken Cochlea innervierten Verbindungen sind gezeigt. (Aus [23])

Systems*. Die anatomischen Gegebenheiten sind - stark schematisiert - illustriert in Fig. 18. Offenbar werden die von der Cochlea ausgehenden Signale in mindestens drei Stufen, insbesondere auch parallel, vorverarbeitet, bevor sie den akustischen Cortex erreichen. Allerdings erreicht die Gesamtzahl der Zellen in den diversen Nuclei nicht einmal 10% der im akustischen Cortex enthaltenen Zellen.

Wir wollen nun die in Abschnitt 12 gemachten Bemerkungen über die Wahl des Stimulus konkretisieren. Hierbei ist zu beachten, daß wir das akustische System, nicht aber das Ohr, analysieren wollen; wir müssen also fordern, daß der gewählte Stimulus durch die Nichtlinearitäten des Ohres möglichst wenig beeinflußt wird.Wir führen hier folgendes Ergebnis an:

I. Jeder Faser des Gehörnervs läßt sich eine "Frequenzgruppe", zentriert um eine "Charakteristische Frequenz", zuordnen, für die sie sensitiv ist. Entsprechendes gilt für die Mehrzahl der Zellen in den nachfolgenden Nuclei. Die räumliche Abbildung der charakteristischen Frequenzen innerhalb der Nuclei ist näherungsweise stetig ("Tonotopie").

Dies legt nahe, als Träger ein Signal zu verwenden, das schmalbandig ist oder aber dessen (schmalbandige)Frequenz-

---

* Für die hier verwendeten Ergebnisse sind keine Einzelreferenzen angegeben; das gesamte Material findet sich in [15].

komponenten in disjunkte Frequenzgruppen fallen. So können wir verhindern, daß Frequenzänderungen infolge der Tonotopie am Ableiteort in Amplitudenänderungen umgesetzt werden. Wir wählen daher als Träger ein periodisches Signal, und zwar Sinus, Dreieck und Rechteck verschiedener Frequenzen.

Es verbleibt die Frage, welchen "langsamen" Parameter wir zur Modulation dieses Trägers benutzen wollen. Zweifelsohne ist einer der wichtigsten Parameter eines akustischen Signals seine Amplitude. Weiter weiß man aus neurophysiologischen Untersuchungen folgendes:

II. Innerhalb der Cochlea findet näherungsweise eine Gleichrichtung des akustischen Signals (also Amplitudendemodulation) statt.

Fig. 19: Antwort einer Faser im Gehörnerv der Katze auf Breitbandrauschen. Die gezeigte Wellenform ist eine schmalbandgefilterte Version des Stimulus. Die schwarzen Balken stellen das Zeit-Histogramm der Faserentladungen, gemittelt über mehrere Darbietungen des pseudozufälligen Stimulus, dar. Man beachte Nichtlinearität und/oder Nullpunktverschiebung der Demodulation (aus [5]).

Diese Eigenschaft ist illustriert in Fig. 19: Die ausgezogene Linie ist eine schmalbandgefilterte Version des Stimulus, und die Faser des Gehörnervs antwortet lediglich auf positive Werte. Auf weitergehende psychophysische Evidenz ("Enveloppenhypothese") wollen wir erst in Abschnitt 18 bei der Interpretation der Ergebnisse eingehen.

Wie groß sollte nun die Bandbreite des Stimulus (also des Rauschens) sein? Hier hilft uns die Psychophysik:

III. Eine Amplitudenmodulation wird oberhalb von etwa* 15 Hz subjektiv nicht mehr als solche, vielmehr als neue Tonqualität (Rauhigkeit) empfunden.

Wenn wir uns also auf den Bereich beschränken, innerhalb dessen Modulation als Lautstärkeschwankung auch empfunden wird, und weiterhin annehmen, daß dieser Effekt auch auf die Versuchstiere (Meerschweinchen) zutrifft, sollte eine Bandbreite von 40 Hz ausreichen. Wir erinnern daran, daß die Bandbreite so niedrig wie nur möglich gewählt werden sollte: Nicht nur sinkt die zur Ermittlung der Kerne benötigte Rechenzeit erheblich, es verringert sich auch - wegen der schnelleren Konvergenz - die notwendige Dauer des Experiments, was die Gefahr von - bei biologischen Präparaten immer zu erwartenden - Nichtstationaritäten verringert.

---

* Wegen der subjektiven Natur dieses Eindrucks ist der Versuch einer genaueren Bestimmung dieses Wertes wenig sinnvc

Die niedrige Bandbreite von 40 Hz hat aber noch einen weiteren, ganz wesentlichen Vorteil, denn es gilt folgendes:

IV. Das Systemgedächtnis des Ohres, gemessen im Gehörnerv, ist abhängig von charakteristischer Frequenz und Bandbreite, liegt aber unter 10 msec.

Da wir bei einer oberen Grenzfrequenz von 40 Hz mit einer Abtastrate von 10 msec auskommen, können - für unsere Zwecke - somit alle Nichtlinearitäten des Ohres als gedächtnisfrei angenommen werden; dies erleichtert, wie wir sehen werden, ganz wesentlich die Interpretation der Kerne.

Wir können nun noch ein weiteres tun, um die Nichtlinearität des Ohres zumindest in eine für unsere Zwecke angenehme Form zu bringen, und zwar gilt

V. Die Entladungshäufigkeit einer Faser im Gehörnerv - oberhalb eines Schwellwerts und unterhalb von Saturation, in einem dynamischen Bereich von 20 bis 50 dB - ist näherungsweise proportional zum Logarithmus der Amplitude des Stimulus.

Falls wir also als Stimulusamplitude statt des Rauschens seine Exponentialfunktion benutzen, können wir auf eine näherungsweise lineare Beziehung zwischen Rauschen und der Aktivität in einer einzelnen Faser des Gehörnervs hoffen. Nun müssen wir bei der Ableitung von Massenpotentialen aber damit rechnen, daß wir über eine Vielzahl

von Zellen mitteln, die ihre Signale selbst wieder aus einer Vielzahl von Fasern mit unterschiedlicher Dynamik beziehen. Hier kann uns wieder die Psychophysik einen Hinweis geben:

VI. Subjektive Lautheit und Eingangsamplitude sind, bei höheren Amplituden, verknüpft durch ein Potenzgesetz der Form $y=x^{\alpha}$, wo etwa $\alpha=0,6$ ist (Stevens' Gesetz).

Offenbar ist dies eine Nichtlinearität vom komprimierenden Typ, und Exponentieren des Stimulus überführt sie gerade in eine vom expandierenden Typ, was uns den Vorzug einer höheren effektiven Dynamik und damit einer besseren Meßbarkeit der Kerne einträgt.

Schließlich müssen wir noch den Ort der Ableitung bestimmen. Das im folgenden Abschnitt beschriebene Experiment war ursprünglich lediglich dazu gedacht, die Frage zu klären, ob Kerne 2. Ordnung bei einem System dieser Komplexität überhaupt meßbar sind. Entsprechend wurde als Ableiteort der Cortex gewählt, und zwar sowohl die Area AI (das primäre Projektionsgebiet) als auch AII ("assoziativer" Cortex). In jedem Fall erscheint es sinnvoll, ein erstes Experiment zunächst am Gesamtsystem auszuführen, um erst später gezielt zu dem interessierenden Teilsystem fortzuschreiten.

15. Das Experiment und die Bestimmung der Kerne

Ausgangspunkt zur Erzeugung des Rauschsignals war eine pseudozufällige Binärfolge, die in einem Schieberegister der Länge 30 mit einer Taktfrequenz von 18,5 kHz erzeugt wurde, was einer Periodizitätslänge von über 16 h entspricht. Dieses Signal wurde anschließend bandpaßgefiltert mit einer unteren und oberen Grenzfrequenz von 0,4 Hz bzw. 40 Hz. Das verwendete Filter (Krohn-Hite 3343) hatte eine Flankensteilheit von 48 dB/Okt. Der Umstand, daß das dritte Moment überall und das vierte Moment bei jeweils zwei ungleichen Argumenten verschwinden sollte, wurde vorsichtshalber experimentell überprüft.

Als Träger verwendet wurden Sinus, Dreieck und Rechteck verschiedener Grundfrequenzen, sämtlich mindestens 2 kHz, um die relative Bandbreite der einzelnen Komponenten gering zu halten. Nach Bildung der Exponentialfunktion des Rauschens wurde diese mit dem Träger multipliziert und dem Versuchstier (Meerschwein) über Kopfhörer vom Typ Sennheiser HD44 monaural dargeboten. Das kontralaterale Ohr war frei und nicht maskiert.

Die Versuche wurden mit insgesamt zwei Versuchstieren ausgeführt. Die Meerschweinchen wurden mit Urethan (1,5 g/kg Körpergewicht intraperitoneal) anästhesiert. Ableiteort war der kontralaterale akustische Cortex (Area AI und AII). Als Elektroden verwendet wurden Glaspipetten gefüllt mit

physiologischer Kochsalzlösung und mit einem Innenwiderstand von etwa 1 MΩ. Das abgeleitete Signal wurde bandpaßgefiltert (0,4 Hz bis 40 Hz, Krohn-Hite 3700, 24 dB/Okt.). Rauschstimulus und Antwort wurden auf FM-Analogband aufgezeichnet und anschließend mit einem 10 bit A/D-Wandler bei einem Abtastintervall von 10 msec (Experiment I) bzw. 6 msec (Experiment II) digitalisiert. Die Weiterverarbeitung erfolgte auf einer UNIVAC 1108. Hier wurden die Daten von Experiment II zunächst phasenverzerrungsfrei tiefpaßgefiltert ($41\frac{2}{3}$ Hz), was in einem effektiven Abtastinvervall von 12 msec resultiert. Während des Experiments konnte die Konvergenz des Kerns 1. Ordnung in Echtzeit auf einem digitalen Korrelator (Honeywell SAI-42A) verfolgt werden.

Beginnen wir mit Experiment I: Ableiteort war AI, die charakteristische Frequenz am Ableiteort betrug 18 kHz. Als Träger verwendet wurde ein Dreieck der Frequenz 2 kHz. Die Gesamtdauer des Experiments betrug 30 min. Die zur Errechnung des Kerns 2. Ordnung erforderliche Rechenzeit entsprach etwa der Echtzeit. Die resultierenden Kerne 1. und 2. Ordnung sind in Fig. 20 dargestellt. Der 3D-Plot (Mitte) wurde mit Hilfe der in [32] beschriebenen Software erstellt; die Linien verlaufen parallel zur Achse $\tau_1=\tau_2$, die Ordinate ist um 30° aus der Ebene herausgedreht. Unten rechts eine Höhenliniendarstellung des Kerns; offenbar ist sein Träger auf einen schmalen Streifen parallel zur Hauptdiagonalen beschränkt. Man beachte den

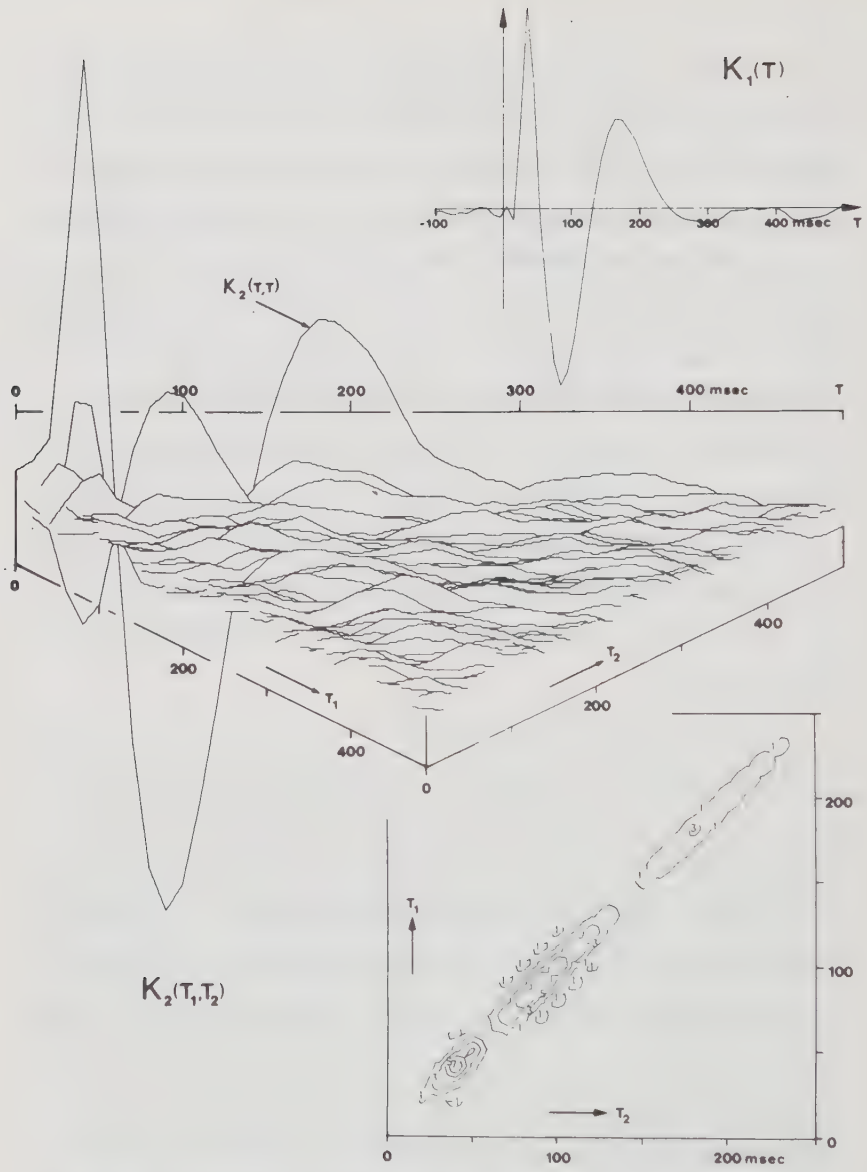

Fig. 20: Darstellung der in Experiment I gemessenen Kerne $K_1(\tau)$ (oben rechts) und $K_2(\tau_1,\tau_2)$ (Mitte, unten rechts). Im 3D-Plot sind die Linien parallel zur Hauptdiagonalen $\tau_1=\tau_2$ gezeichnet, die Ordinate ist um 30^o aus der Bildebene herausgedreht. Alle Ordinatenmaßstäbe sind willkürlich. Die Zahlenmarkierungen der Linien in der Höhenliniendarstellung (rechts unten) ergeben, mit 10 multipliziert, die Prozentzahl des Maximalwertes. Die scheinbare Asymmetrie ist auf Eigenschaften der Plottersoftware zurückzuführen.

sehr ähnlichen Verlauf von K_1 und dem Diagonalterm von K_2.

Um zu demonstrieren, inwieweit die diversen Kerne zur Antwort beitragen, greifen wir hier auf die Ergebnisse des folgenden Abschnitts vor (vgl. Fig. 23): Fig. 21 zeigt einen Ausschnitt der Dauer 5,12 sec aus Rauschstimulus (Spur A) und Antwort (B). Die Spuren F, E und D zeigen den linearen, quadratischen und kubischen Anteil, zu deren Berechnung jeweils nur die Anteile in der Hauptdiagonalen der Kerne verwendet wurden; in Spur C ist ihre Summe aufgetragen. Zwar werden einige Wellenformen fast

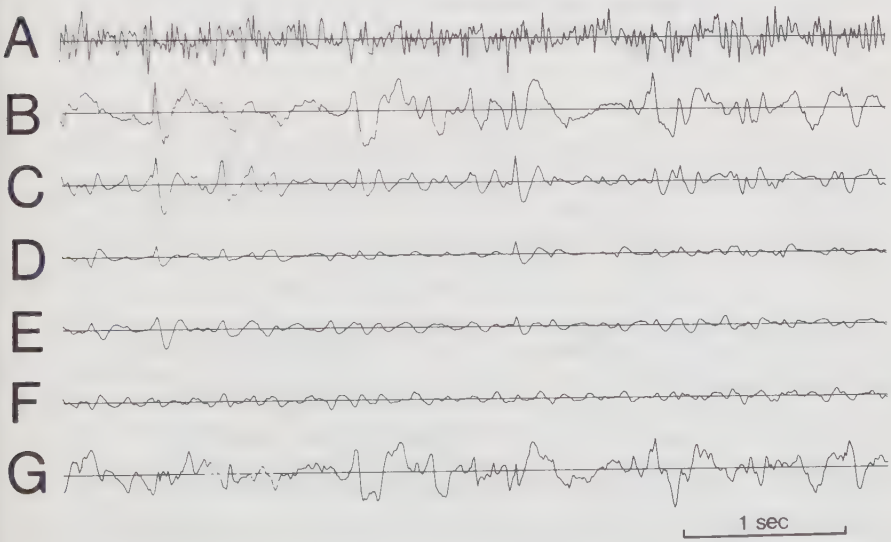

Fig. 21: Ausschnitte der Länge 5,12 sec aus Stimulus (A), Antwort (B), linearem Anteil (F), quadratischem Anteil (E), kubischem Anteil (D). C: Summe von D, E, F. G: Differenz zwischen B und C. Nur Diagonalterme wurden zur Berechnung von D und E benutzt.

vollständig schon durch die drei ersten Kerne erklärt (etwa die steile Welle ganz links), doch scheint der größte Teil der cortikalen Aktivität zunächst einmal keinen Zusammenhang mit dem Reiz zu haben; die Differenz zwischen der Summe der drei ersten Terme (C) und der Antwort (B) ist in Spur G dargestellt. Im einzelnen beträgt die Energie der Anteile in Prozenten der Energie der Antwort

linear	: 6,6%
quadratisch	: 10,6%
kubisch	: 5,8%
Summe	: 34,1%

Die Energie der Summe ist nicht gleich der Summe der Einzelenergien, da die hier verwendete Entwicklung (13.2) - im Gegensatz zu (13.5) - nicht orthogonal ist.

Nachdem mit diesem Langzeitexperiment die Meßbarkeit der Kerne erwiesen war, wurden in einem zweiten Experiment an einem zweiten Versuchstier insgesamt sechs Versuche durchgeführt, die Abhängigkeiten vom Ableiteort und vom verwendeten Träger darstellen sollten. Effektives Abtastintervall war hier 12 msec. Tabelle I gibt eine Übersicht über die verwendeten Versuchsparameter:

Tabelle I: Übersicht über in Experiment II verwendete Versuchsparameter

Versuch	Ableiteort	Träger-frequenz (kHz)	Trägerart	charakt. Frequenz (kHz)
A	A I	7,2	Sinus	7,2
B	A II	3,0	Sinus	3,0
C	A II	3,0	Rechteck	3,0
D	A II	3,0	Sinus	3,0
E	A II	10,0	Sinus	3,0
F	A II	10,0	Rechteck	3,0

Die zeitliche Dauer jedes Versuchs betrug 6'3". Die resultierenden Kerne 1. und 2. Ordnung sind - mit auf den Maximalwert normierter Ordinate - in Fig. 22 dargestellt. Offensichtlich sind sie im Rahmen dieses Experiments unabhängig von der Trägerart, vom Ableiteort und von der Trägerfrequenz; dies ist besonders erstaunlich in Versuch E und F, wo die Trägerfrequenz weit oberhalb der charakteristischen Frequenz liegt. Man beachte die Beschränkung des Trägers der Kerne 2. Ordnung auf eine Umgebung der Hauptdiagonalen und die Ähnlichkeit von Hauptdiagonalterm und Kern 1. Ordnung. Eine bemerkenswerte Abweichung vom üblichen Verhalten zeigt lediglich der Kern 1. Ordnung in Versuch B (einen scharfen Einbruch in der negativen Halbwelle); wir werden eine Erklärung für dieses Phänomen in Abschnitt 17 geben.

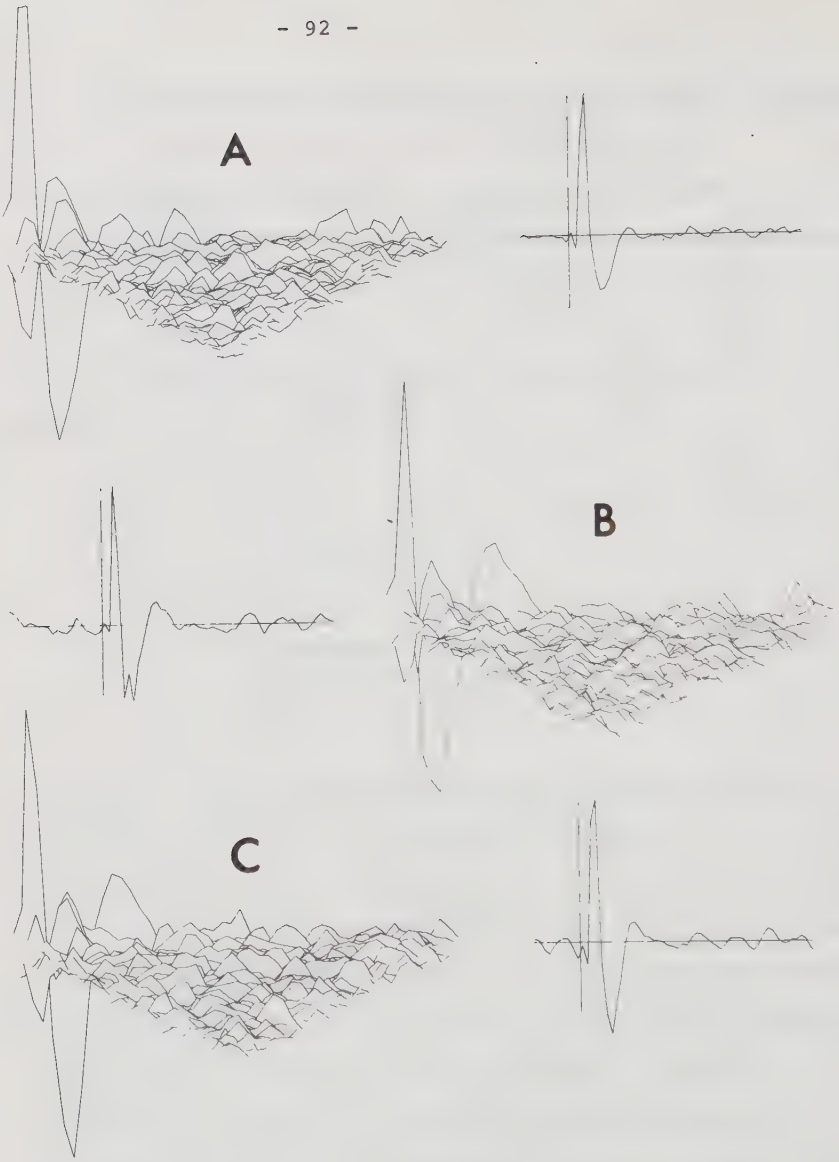

Fig. 22: Darstellung der aus Experiment II gewonnenen linearen und quadratischen Kerne. Die Abszissenmaßstäbe sind unten auf der nächsten Seite angegeben.

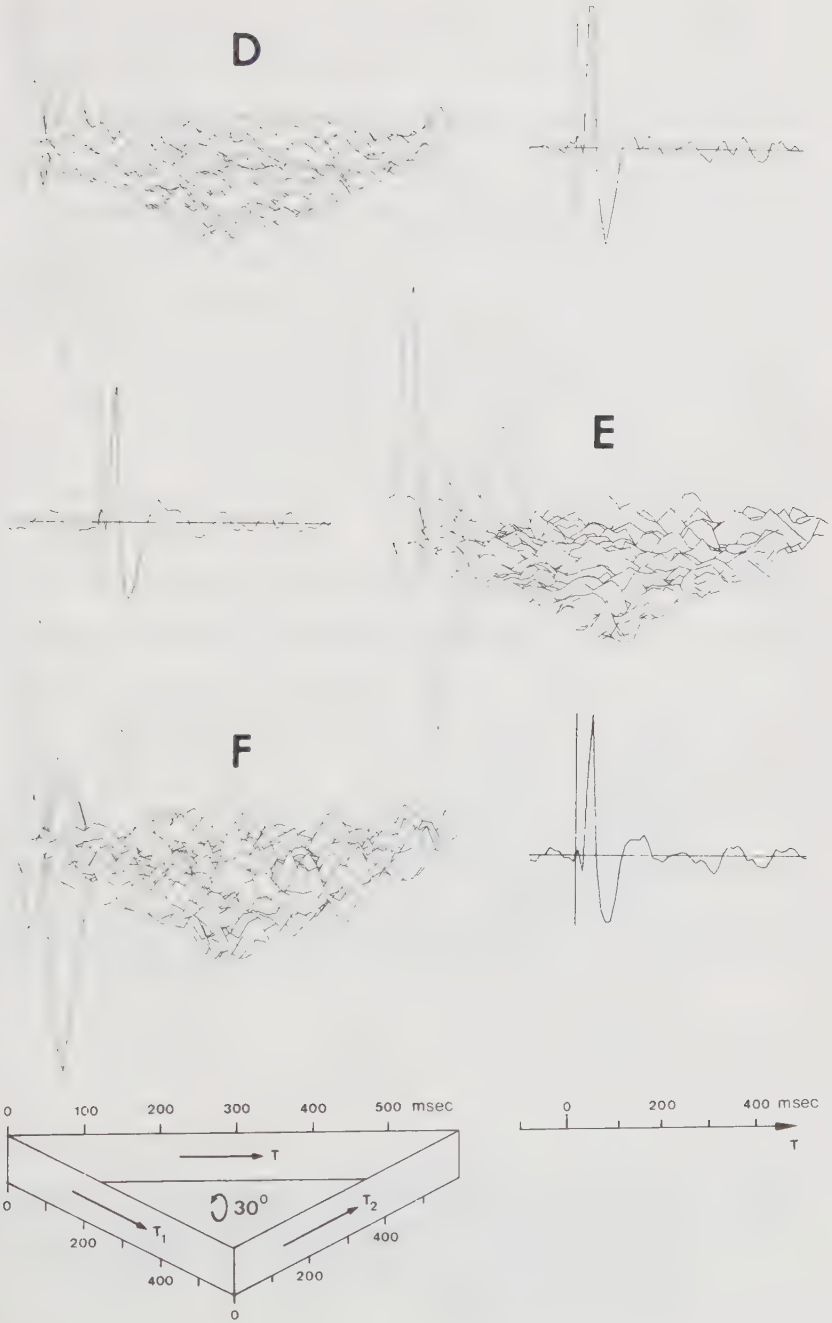
D
E
F
0
100
200
300
400
500 msec
T
30°
T_1
T_2
0
200
400
0
200
400
0
200
400 msec
T

16. Interpretation der Kerne

Die Kerne K_1 und K_2 sind Bestandteile einer funktionalen Beschreibung des Systems; wie wir gesehen haben, erklären sie in Experiment I etwa 17% der Leistung des Ausgangssignals. Selbst diesen Teil des Systems aber beschreiben die Kerne lediglich in Form einer Datenreduktion: Der Nachteil der funktionalen Beschreibung ist, daß sie nichts "bedeutet"; sie darf lediglich als Zwischenschritt auf der Suche nach der endgültigen (strukturellen) Modellierung des Systems verstanden werden.

Gehen wir zunächst zurück zu Experiment I. Wir hatten schon gesehen, daß der Träger von K_2 auf einen schmalen Streifen

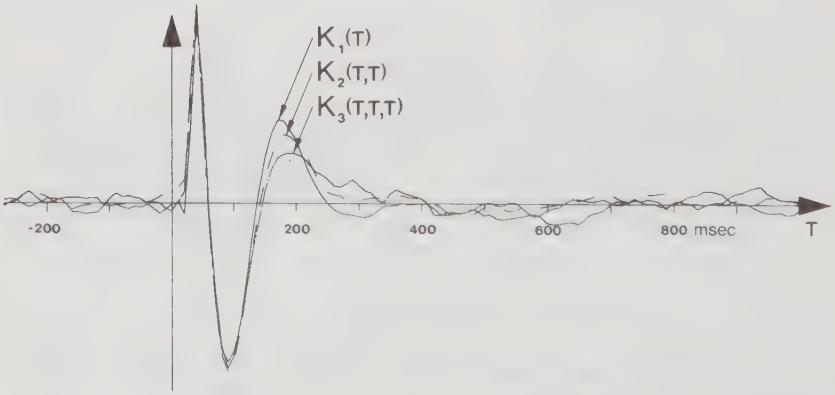

Fig. 23: Hauptdiagonalschnitte durch die Kerne erster (ausgezogen), zweiter (gestrichelt) und dritter (strichpunktiert) Ordnung. Normierung der Ordinaten auf gleichen Maximalwert.

längs der Hauptdiagonalen beschränkt ist, und darauf hingewiesen, daß der Verlauf längs der Hauptdiagonalen dem von K_1 sehr ähnelt. In Fig. 23 sind zum besseren Vergleich die Diagonalschnitte durch die drei ersten Kerne superponiert. Ihr weitgehend gleicher Verlauf legt folgende Vermutung nahe:

Hypothese Die Kerne K_n haben die Struktur

$$K_n(\tau_1,\ldots,\tau_n) = k_n\int H(\tau)\,\delta(\tau-\tau_1)\ldots\delta(\tau-\tau_n)\,d\tau \qquad (16.1)$$

Nun ist aus Fig. 20 ersichtlich, daß K_2 Träger auch neben der Hauptdiagonalen hat. Dieser Umstand wird erklärt durch das in Abschnitt 13 eingeführte (hypothetische) Filter A, das das (hypothetische) weiße Rauschen in das im Experiment verwendete Bandpaßrauschen überführt; siehe dazu Fig. 17. Da dieses Filter vor jeder Nichtlinearität liegt, wird entsprechend Formel (13.15) jeder Punkt der Hauptdiagonalen von K_2 in einem Quadranten, mithin die gesamte Hauptdiagonale in einem Streifen der Breite $\sqrt{\mu}$, ausgeschmiert, wo μ das Systemgedächtnis von A ist. Wenn die obige Hypothese richtig ist, können wir also lediglich messen

$$K_n(\tau_1,\ldots,\tau_n) = k_n\int H(\tau)\,A(\tau-\tau_1)\ldots A(\tau-\tau_n)\,d\tau \qquad (16.2)$$

Um dies zu überprüfen, wurde der Kern 2. Ordnung aus Experiment I, $K_2(\tau_1,\tau_2)$, parallel zu $\tau_1=\tau_2$ mit $K_1(\tau)$ dekonvolviert. Das nach (16.2) zu erwartende Ergebnis ist

$$K_{2,dec}(\tau_1,\tau_2) = k\int A^{-1}(\tau)A(\tau-\tau_1)A(\tau-\tau_2)d\tau \qquad (16.3)$$

wo durch A^{-1} das zu A inverse Filter bezeichnet ist.

Das tatsächliche Ergebnis ist in Fig. 24, rechts, dargestellt. Der singuläre Wert bei (o,o) ist von einem ovalen Trog umgeben, wobei die ovale Form vermutlich auf das Ausschmieren längs der Diagonalen mit A^{-1} zurückzuführen ist.

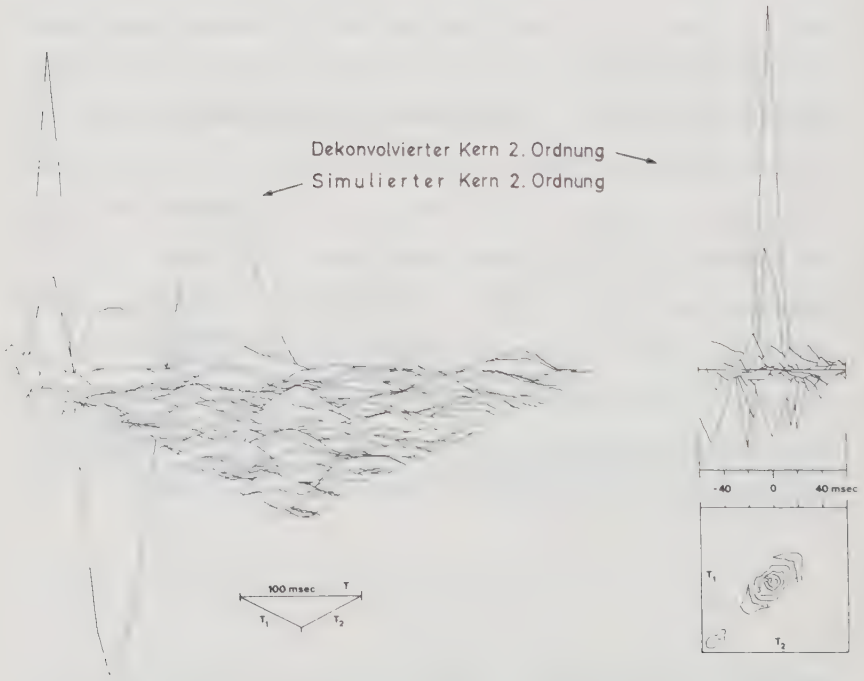

Fig. 24: Links der simulierte Kern 2. Ordnung (vgl. Fig. 20). Rechts der dekonvolvierte Kern 2. Ordnung, wie üblich parallel zur Hauptdiagonalen gezeichnet; die Ordinate liegt in der Bildebene.

Links in Fig. 24 zeigen wir noch einen simulierten Kern 2. Ordnung, der mit dem in Fig. 20 dargestellten verglichen werden sollte. Er benutzt als Eingangssignal den tatsächlichen Stimulus, als Ausgangssignal das mit $K_1(\tau)$ gefaltete quadrierte Eingangssignal. Seine theoretische Gestalt ist also (gemäß obiger Hypothese)

$$K_{2,sim}(\tau_1,\tau_2) = \int H(\tau-\sigma)A(\tau-\tau_1)A(\tau-\tau_2)d\tau A(\sigma)d\sigma \quad (16.4)$$

und sollte sich entsprechend (16.2) vom gemessenen K_2 nur durch Verschmierung parallel zur Hauptdiagonalen unterscheiden; der Vergleich mit Fig. 20 zeigt, daß dies gut erfüllt ist. Wir können die obige Hypothese nun in folgende Aussage über die Struktur des Systems umsetzen:

> Der (direkte) Modulationstransfer im akustischen System läßt sich beschreiben als <u>lineare</u> Filterung, der eine Nichtlinearität mit einem Systemgedächtnis unter 10 msec vorausgeht.

Die im zweiten Experiment gewonnenen Kerne 2. Ordnung sind für eine Dekonvolution zu verrauscht; immerhin läßt ihre Inspektion sie als mit unserer Hypothese kompatibel erscheinen. Dies vereinfacht alle weiteren Betrachtungen ganz erheblich, bedeutet es doch gerade folgendes:

> Bei allen folgenden Untersuchungen können wir uns auf die Analyse des linearen Anteils allein beschränken.

Zur Untersuchung der Struktur des Filters wollen wir einen

konstruktivistischen Zugang wählen und überlegen, welche Eigenschaften es besitzen sollte. Sein Leistungsspektrum ist bestimmt durch die "Wichtigkeit" der einzelnen Frequenzbänder für das nachfolgende System, über das wir nichts wissen; es verbleibt also Freiheit bei der Wahl des Phasenganges.

Wir merken an, daß eine sehr wichtige Funktion unserer Sinnesorgane ist, uns vor möglichen Gefahren in der Umwelt zu warnen; dementsprechend sollten wir eine maximale Verarbeitungsgeschwindigkeit der eintreffenden Reize fordern; anders gesagt, es sollte die mittlere Gruppenlaufzeit $\bar{\tau}_g$ im verarbeitenden System minimiert werden. Was bedeutet dies für ein lineares Filter mit vorgeschriebenem Spektrum? Die Gruppenlaufzeit ist definiert durch $\tau_g = \frac{d\phi}{d\omega}$, wo ϕ der Phasengang des Filters ist; Integration über ω zeigt, daß die minimale mittlere Laufzeit gerade durch ein Filter minimaler Phase (vgl. Abschnitt 4) gewährleistet wird, das man daher auch als "Filter minimaler Verzögerung" bezeichnet.

Um zu sehen, ob die Evolution diesen Weg eingeschlagen hat, wurde zu den Kernen 1. Ordnung jeweils das entsprechende minimalphasige Filter auf folgende Weise berechnet: Nach Ermittlung der Autokorrelationsfunktion (Wegfall der Phaseninformation) wurde ein Prädiktor* der Länge 15 be-

---

* Vgl. Fußnote Seite 14

rechnet (dies entspricht zugleich einer Glättung des Spektrums); Invertierung dieses Prädiktors liefert das zugehörige Filter minimaler Phase. Da die linearen Kerne in Experiment II einerseits verrauscht, andererseits einander sehr ähnlich sind, wurde ein totaler linearer Kern durch Mittelung über die jeweiligen linearen Kerne in den einzelnen Versuchen ermittelt. Das Resultat ist in Fig. 25 dargestellt (gemessene Filter: gestrichelt; minimalphasige Filter: ausgezogen). Wenn wir bedenken, daß die dort gezeigten Funktionen gerade die Antwort auf einen 'Klick' (also einen Puls von etwa 10 msec Dauer in der Modulation) darstellen, sehen wir direkt, daß die

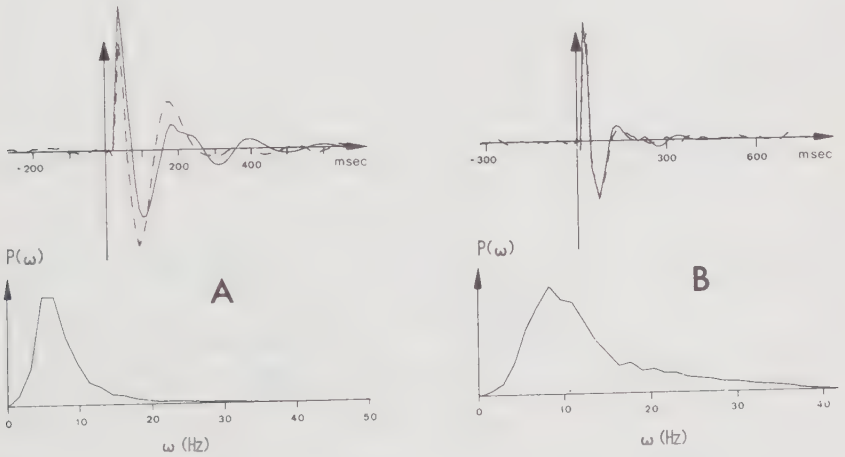

Fig. 25: Die Kerne 1. Ordnung (gestrichelt) aus Experiment I (A) und Experiment II (B, gemittelt über alle Versuche) zusammen mit der superponierten Version minimaler Verzögerung (ausgezogen); darunter das jeweilige gemeinsame Leistungsspektrum. Ordinate der Kerne normiert auf gleiche Energie.

tatsächlichen Filter in der Tat fast die minimale Verzögerung erreichen; in Experiment II ist die Übereinstimmung perfekt.

Unten in Fig. 25 sind die jeweiligen (gemeinsamen) Leistungsspektren gezeigt. Der maximale Transfer wird erreicht bei etwa 6 Hz (Experiment I) bzw. 8 Hz (Experiment II). Der Abfall der Bandpaßfilter nach beiden Seiten beträgt etwa 10 dB/Okt. (vgl. Fig. 26).

17. Instationäres Verhalten

Wie wir in Abschnitt 15 gesehen haben, weist der Kern 1. Ordnung in Versuch IIB eine merkwürdige Form auf: In der negativen Exkursion zeigt er einen scharfen Einbruch (vgl. Fig. 22). Dies legt nahe, zu untersuchen, ob dieses Verhalten von den Versuchsparametern abhängt oder etwa auf Instationaritäten des Systems zurückzuführen ist. Da sich dabei zeigte, daß sich die wesentlichen Punkte am deutlichsten anhand von Versuch IIC nachweisen lassen, wollen wir uns auf diesen von nun an beschränken. In Fig. 26 werden die Leistungsspektren von Antwort und linearem Anteil in logarithmischer Darstellung gezeigt; maximaler Transfer wird bei etwa 10 Hz erreicht, der Abfall beträgt etwa 10 dB/Okt. nach beiden Seiten, insofern zeigt das Filter also keine Abweichung vom erwarteten Verhalten. Man beachte, daß der Abfall des Antwortspektrums

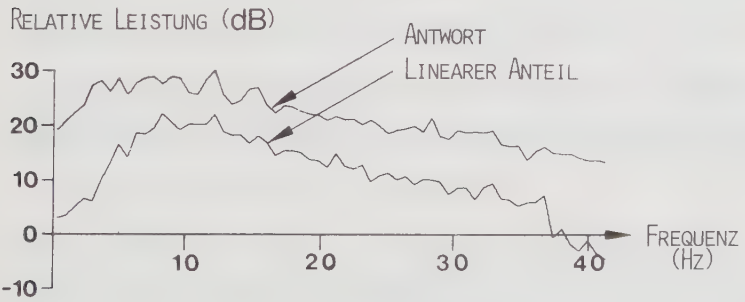

Fig. 26: Leistungsspektra von Antwort und linearem Anteil der ersten 3 min aus Versuch IIC. Die Gesamtleistung des linearen Anteils erreicht 13% der Leistung der Antwort.

wesentlich geringer ist (etwa 7 dB/Okt.), was teilweise mit den nichtlinearen Eingangstermen zusammenhängen mag, zum größten Teil aber auf mit der Modulation nicht zusammenhängende Cortexaktivitäten zurückzuführen sein dürfte.

Um nun den möglichen Einfluß von Instationaritäten zu untersuchen, wurde folgende Methode verwandt: Jeweils von Stimulus und Antwort wurden 2^{13} Datenpunkte - das entspricht einem Zeitraum von 1'38" - in 16 Blöcke zu je 2^{9} Datenpunkten - entsprechend 6,14 sec - aufgespalten. Für jeden dieser Blöcke wurden berechnet:

1. Die Kreuzkorrelation zwischen Stimulus und Antwort, also der Kern 1. Ordnung und damit eine Schätzung des linearen Filters.
2. Das daraus resultierende Leistungsspektrum des linearen Anteils.
3. Das Leistungsspektrum der Antwort.
4. Die Kreuzkorrelation zwischen Stimulus und nichtlinearem Residuum. Dieses Residuum ist definiert als die Differenz aus Antwort und dem unter Verwendung des in Fig. 22C abgebildeten totalen linearen Kerns geschätzten linearen Anteil.

Eine signifikante Korrelation in (4) bedeutet demnach, daß das momentane Verhalten des Filters von seinem "üblichen" Verhalten erheblich abweicht.

Fig. 27 zeigt das Resultat dieser Untersuchung. Alle Ordinatenmaßstäbe sind willkürlich, aber gleich jeweils für alle

Blöcke sowie für die beiden Kreuzkorrelationen.

Während der ersten vier Blöcke finden wir "normales" Verhalten: Stimulus und Residuum sind nicht signifikant korreliert, das gemessene - stark verrauschte - Filter hat die erwartete Struktur, maximaler Transfer wird bei etwa 11 Hz erreicht. Dann eine plötzliche Veränderung: Die Leistung der Cortexaktivität sinkt (auf 37%, entsprechend -4,3 dB, Blöcke 5-10 verglichen mit 1-4), ebenso die Energie des Filters (auf 49% $\hat{=}$ -3,1 dB). Gleichzeitig werden die Spektren weitgehend flach; man beachte aber, daß nicht einfach der niederfrequente Anteil abnimmt, sondern der höherfrequente Anteil im Gegensatz dazu ansteigt. Stimulus und Residuum sind nun deutlich korreliert. Diese Situation bleibt weitgehend unverändert über sechs Blöcke (mehr als eine halbe Minute), dann erfolgt innerhalb von Block 11 die Rückkehr zu wieder relativ "normalem" Verhalten, wie wir daran sehen, daß das Residuum nun mit dem Stimulus nicht mehr korreliert ist. Die Leistung der Antwort steigt wieder an (um 3,7 dB, gemittelt über Blöcke 12-16); dagegen bleibt die Energie des Filters nahezu unverändert (sie sinkt um weitere 0,4 dB), obwohl das zugehörige Spektrum zu seiner Tiefpaßform zurückkehrt.

Wie wir sehen, haben wir hier in der Tat ein nicht-stationäres Verhalten vor uns, doch von besonderer Art: Die Charakteristik des Filters verändert sich nicht etwa kontinuierlich, vielmehr scheint das Filter verschiedene,

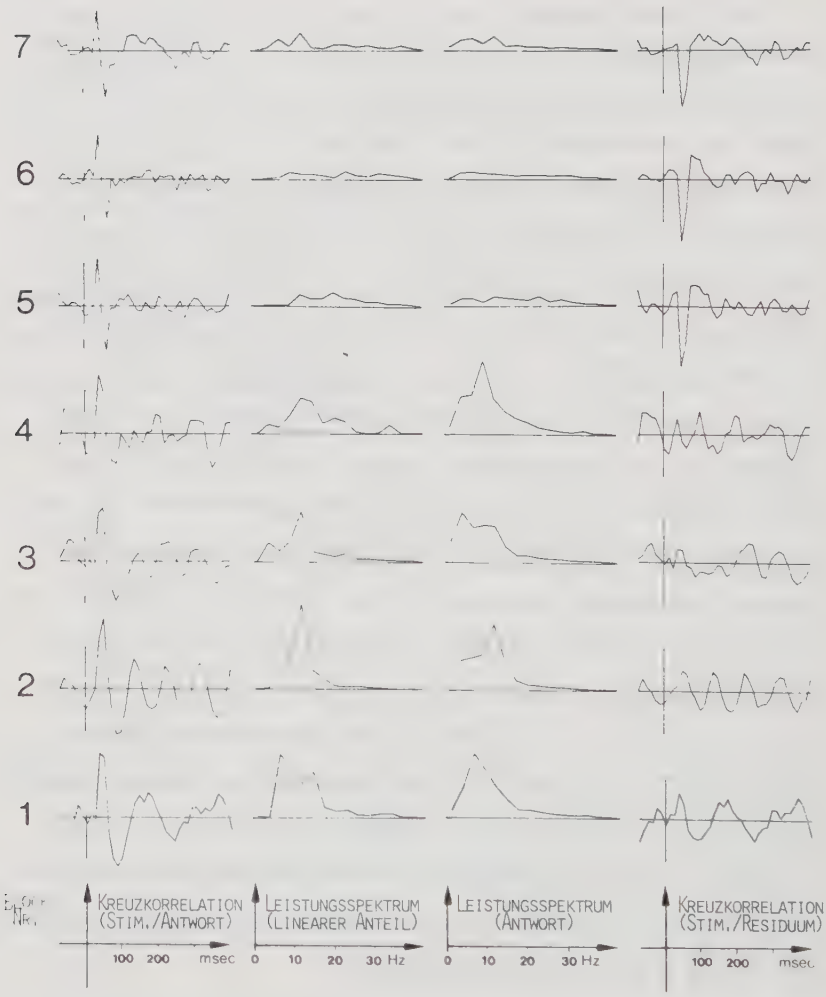

Fig. 27: Kurzzeitanalyse eines Ausschnitts der Länge 1'38" aus Versuch IIC in 16 Blöcken zu je 6,14 sec. Gleiche Ordinatenmaßstäbe für alle Blöcke sowie für die beiden Kreuzkorrelationen. Man beachte die Aufteilung in "normales" Verhalten (Blöcke 1-4, 12-16) und "abnormes" Verhalten (Blöcke 5-10); in Block 11 findet ein Übergang statt.

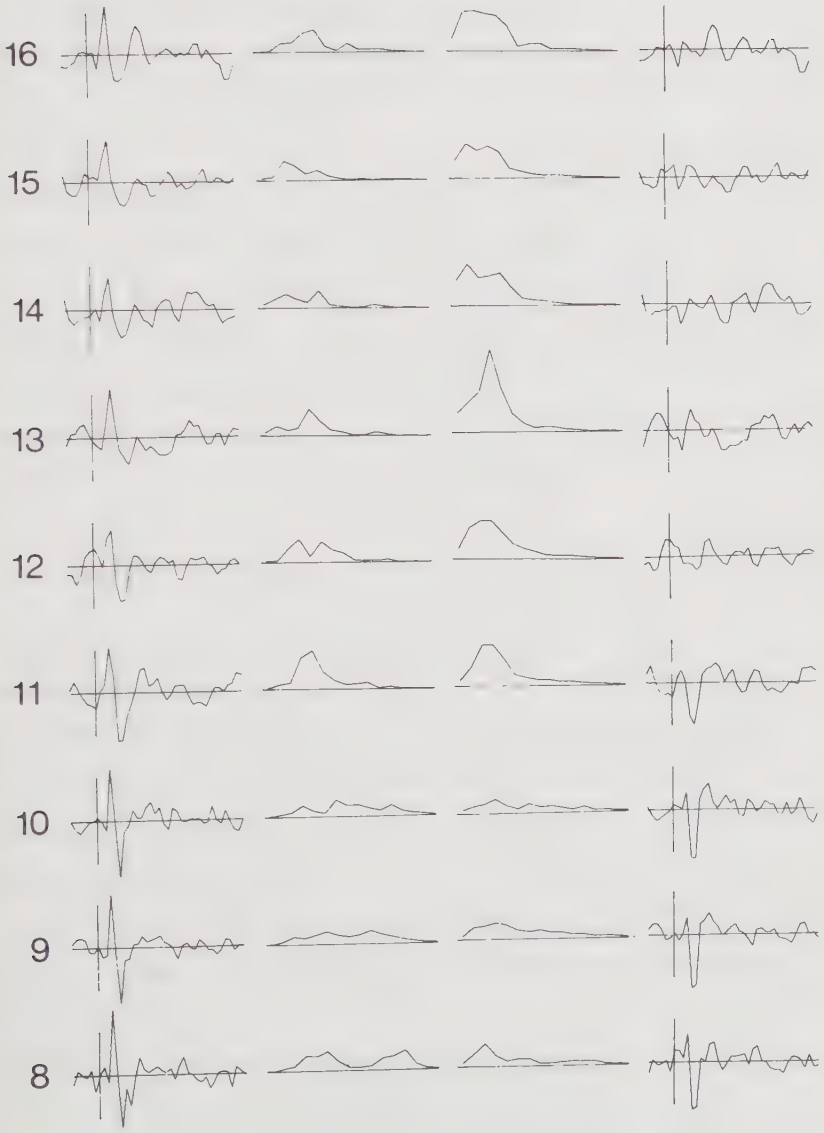
16
15
14
13
12
11
10
9
8

Leerseite

Bitte ausschneiden und oben auf S. 104 kleben

selbst aber wieder stationäre, Zustände annehmen zu können; beide Formen wechseln einander ab, und ihre Überlagerung führt zu der in IIB gemessenen Form (vgl. die Form des Filters in Fig. 27, Block 8).

Es wäre nun interessant zu wissen, ob der seltenere, hier "abnorm" genannte, Zustand des Filters einem (nicht beabsichtigten) Zusammenbruch des Systems entspricht, oder ob dies einfach eine alternative, momentan bevorzugte Form der Signalverarbeitung darstellt. Zu diesem Zweck wurden die Impulsantworten der Filter in den beiden Zuständen durch Mittelung wie folgt bestimmt:
A ("normales" Verhalten): Blöcke 1-4, 12-16
B ("abnormes" Verhalten): Blöcke 5-7, 9, 10

Blöcke 8 und 11 wurden als Übergangssegmente nicht verwendet. Die Ergebnisse sind in Fig. 28, oben dargestellt; die gemittelten Impulsantworten sind gestrichelt, ausgezogen superponiert die entsprechenden Impulsantworten minimaler Verzögerung. Darunter (a und b) die zugehörigen Leistungsspektren. Offenbar ist im "abnormen" Zustand die minimalphasige Struktur weitgehend erhalten; die Übereinstimmung ist in (A) nahezu perfekt, in (B) besser nicht zu erwarten, da hier der Einfluß des Abschneidens bei 40 Hz nicht mehr vernachlässigbar sein dürfte. Offenbar wirkt (B) im wesentlichen als Allpaß; dies hat den Vorzug, daß der Energietransfer im wesentlichen schon nach 45 msec (gegenüber 90 msec in (A)) abgeschlossen ist: Also eine Erhöhung der Verarbeitungsgeschwindigkeit auf das doppelte.

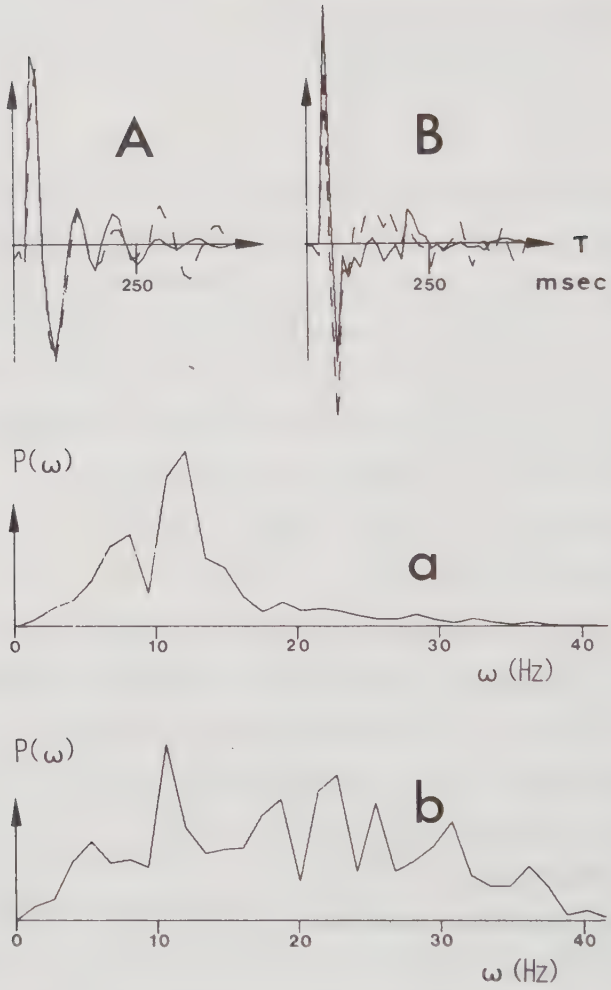

Fig. 28: Oben: Gemessene (gestrichelt) und minimalphasige (ausgezogen) Impulsantwort. A: Gemittelt aus Blöcken 1-4, 12-16. B: Gemittelt aus Blöcken 5-7, 9, 10 (vgl. Fig. 27). a: Leistungsspektrum zu A. b: Leistungsspektrum zu B.

18. Ein strukturelles Modell

In Abschnitt 16 haben wir gesehen, daß die Information über Amplitudenmodulation niedriger Frequenz praktisch verzerrungsfrei zum Cortex weitergeleitet wird: Wir sind auf unserer Suche nach nichtlinearer Wechselwirkung auf ein lineares System gestoßen. Um dieses zu verstehen, wollen wir zunächst wohlbekannte Hinweise dafür anführen, daß Amplitudenmodulation nicht nur ein wichtiger, sondern womöglich - nach der Information über den spektralen Gehalt, der ja schon im Ohr ermittelt wird - der wichtigste Parameter eines akustischen Signals ist.

Seit langer Zeit weiß man, daß Ohr und akustisches System weitgehend phasenunempfindlich sind (Ohm's Gesetz); die in jüngerer Zeit gefundenen Abweichungen (siehe [29] für einen Überblick) sind in ihrer Mehrzahl verträglich mit der Enveloppenhypothese, die besagt, daß das System - nach der Aufspaltung in Frequenzgruppen - lediglich die Umhüllende der resultierenden Signale zur Weiterverarbeitung benutzt. Diese Umhüllende ist aber in unserem Fall eines reinen Tones bzw. einer Kombination von reinen Tönen in disjunkten Frequenzgruppen als Träger gerade die Amplitudenmodulation.

Unter diesen Umständen erscheint es sinnvoll, diese wichtige Information verzerrungsfrei weiterzuleiten, doch ist eine Bandbegrenzung nötig; und zwar einerseits zum

Zweck der Datenreduktion - der wesentliche Effekt jeder Merkmalsgewinnung -, weiterhin scheint der Cortex nicht in der Lage zu sein, mit Signalen oberhalb von etwa 40 Hz zu arbeiten: Dies bleibt spezialisierten Strukturen vorbehalten (etwa dem Kleinhirn oder den Olivenkernen, die in der Lage sind, binaurale Zeitdifferenzen noch unter 10 µsec festzustellen).

Nun werden Modulationsfrequenzen oberhalb von etwa 20 Hz aber nicht einfach vernachlässigt: Vielmehr wird - für einen Frequenzbereich, der etwa der Frequenzgruppenbreite des Trägers entspricht - ein neues Merkmal extrahiert, die "Rauhigkeit", die hier den Modulationsgrad in sehr summarischer Form darstellt; für diesen Parameter dürfen wir eine sehr niedrige Bandbreite annehmen.

Oberhalb der Frequenzgruppenbreite dagegen ist ein spezieller Mechanismus gar nicht mehr erforderlich: Hier sorgt die durch die Modulation bewirkte breitbandige Aufspaltung des Signals in mehrere Frequenzgruppen hinein schon für die erforderliche Charakterisierung.

Ein weiterer interessanter Punkt ist die Isolierung zweier verschiedener stabiler Zustände im vorangehenden Abschnitt. In diesem Zusammenhang sei einige beiläufige Evidenz erwähnt, die während des Experiments gesammelt wurde, sich aber - da sie damals nicht als signifikant erkannt wurde und dementsprechend keine Zeitmarkierungen angebracht

wurden - nicht objektiv erhärten läßt. Wie schon gesagt, war das kontralaterale Ohr der Versuchstiere frei, und die Konvergenz des Kerns 1. Ordnung konnte während des Experiments in Echtzeit verfolgt werden. Dabei fiel zeitweise - insbesondere in Versuch IIB - auf, daß die in Fig. 22B gezeigte gezackte Struktur auftrat. Es zeigte sich nun, daß sich das "normale" Konvergenzverhalten durch vom Stimulus qualitativ verschiedene Reize mit hohem Aufmerksamkeitswert - Pfeifen, Klopfen, nicht zuletzt das schon notorische Schlüsselklirren - zumindest für eine gewisse Zeit wiederherstellen ließ. Dies legt folgende Interpretation der beiden in Fig. 28 dargestellten Zustände nahe:

> Das lineare Filter arbeitet in (mindestens) zwei diskreten Moden, charakterisiert durch
> Modus I ("normal"): Herausfiltern des für den Cortex interessanten Frequenzbereiches; Ziel: Klassifikation des Reizes.
> Modus II ("abnorm"): Maximal schneller Durchlaß des Reizes; Ziel: Möglichst schnelle Reaktion auf einen neuartigen Reiz, gleichgültig, welcher Struktur.

Ein weiterer Punkt, der für diese Interpretation spricht, ist, daß in Modus II die Cortexaktivität stark abnimmt, was verträglich ist mit der dann wesentlich einfacheren Weiterverarbeitung. Falls diese Interpretation richtig ist, muß das Filter vom Cortex gesteuert werden. Gerade dies aber ist im akustischen System unproblematisch: Wir hatten in Fig. 18 lediglich das afferente System dargestellt und nicht erwähnt, daß das akustische System - im Vergleich etwa mit

dem optischen System - sehr stark efferent innerviert ist; so beziehen etwa Geniculatum und Colliculus inferior direkte Afferenzen aus dem Cortex.

Wir können unsere Überlegungen nun zusammenfassen in folgender Hypothese: Der Modulationstransfer im akustischen System wird vermittelt durch ein lineares Bandpaßfilter minimaler Verzögerung, dessen Charakteristik cortikal steuerbar ist.

Das vorgeschlagene Modell der Modulationsverarbeitung ist schematisiert in Fig. 29 angegeben.

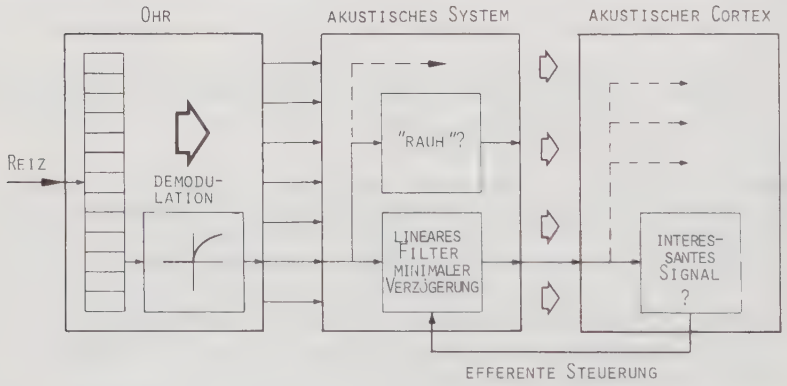

Fig. 29: Hypothetische Struktur der Modulationsverarbeitung im akustischen System. Im Ohr findet die Aufspaltung in Frequenzgruppen sowie Demodulation mit nichtlinearer Kennlinie statt (Dynamikkompression). Man beachte, daß diese Nichtlinearität als gedächtnisfrei nur im Rahmen der hier verwendeten oberen Grenzfrequenz von 40 Hz angesehen werden kann; weiterhin wird binaurale Interaktion nicht berücksichtigt. Im akustischen System erfolgt Bandpaßfilterung minimaler Verzögerung sowie die Extraktion des Parameters "Rauhigkeit". Die resultierenden Signale werden im Cortex analysiert; ist das Signal "uninteressant", so kann das Filter entsprechend umgesteuert werden.

Literaturverzeichnis

[1] Akaike, H., Autoregressive Model Fitting for Control, Ann. Inst. Statist. Math., 23, 163-180, 1971

[2] Atal, B.S., und M.R. Schroeder, Adaptive Predictive Coding of Speech Signals, Bell Syst. Tech. J., 49, 1973-1986, 1970

[3] Brockett, R.W., Nonlinear Systems and Differential Geometry, Proc. IEEE, 64, 61-72, 1976

[4] Creutzfeldt, O.D. (Hrsg.), The Neuronal Generation of the EEG, in: Handbook of Electroencephalography and Clinical Neurophysiology (Hrsg.: A. Remond), Elsevier, Amsterdem 1974

[5] De Jongh, H.R., About Coding in the VIIIth Nerve, in: Hearing Theory 1972, 70-77, Eindhoven: IPO 1972

[6] Porter, W.A., An Overview of Polynomic System Theory, Proc. IEEE, 64, 18-23, 1976

[7] Dolce, G., und H. Künkel (Hrsg.), CEAN: Computerized EEG Analysis, Fischer, Stuttgart 1975

[8] Dubes, R.C., Pattern Recognition with Clinical Electroencephalograms, Div. of Eng. Res., Michigan State Univ., AFOSR-1023-67B, 1970

[9] Fenwick, P.B.C., P. Michie, J. Dollimore und G.W. Fenton, Mathematical Simulation of the Electroencephalogram Using an Autoregressive Series, Int. J. Bio. Comp, 2, 281-3o7, 1971

[1o] Flik, T., Verfahren zur automatischen Erkennung von Mustern in biomedizinischen Signalen mit spezieller Anwendung auf Spike-Wave-Komplex-Erkennung im Elektroenzephalogramm, Dissertation, FB Kybernetik, TU Berlin 1973

[11] Gersch, W., Spectral Analysis of EEG's by Autoregressive Decomposition of Time Series, Math. Biosciences, 7, 2o5-222, 197o

[12] Gibbs, F.A., und E.A. Gibbs, Atlas of Electroencephalography (Bde 1 und 2), Addison-Wesley, Cambridge (Mass.) 195o

[13] Grenander, U., und G. Szegö, Toeplitz Forms and their Applications, Univ. California Press, Berkeley 1958

[14] Itakura, F., und S. Saito, Analysis Synthesis Telephony Based Upon the Maximum Likelihood Method, Reports of the 6th Int. Cong. Acoust. (Hrsg. Y. Kohasi), Tokio 1968

[15] Keidel, W.D., und W.N. Neff (Hrsg.), Handbook of Sensory Physiology, Bd. V: Auditory System, Springer, Berlin 1975

[16] Lee, Y.W., und M. Schetzen, Measurement of the Wiener Kernels of a Nonlinear System by Cross-Correlation, Int. J. Contr., 2, 237-254, 1965

[17] Levinson, N., The Wiener RMS (Root Mean Square) Error Criterion in Filter Design and Prediction, in [33]

[18] Lopes da Silva, F.H., A. Dijk und H. Smits, Detectio of Nonstationarities in EEG's Using the Autoregressive Model - an Application to EEG's of Epileptics, in [7]

[19] Makhoul, J., Linear Prediction: A Tutorial Review, Proc. IEEE, 63, 561-58o, 1975

[2o] Markel, J.D., und A.H. Gray, Linear Prediction of Speech, Springer, Berlin 1976

[21] Maramelis, P.Z., und K.I. Naka, Identification of Multi-input Biological Systems, IEEE Trans. Biomed Eng., 21, 88-1o1, 1974

[22] McCann, G.D., und P.Z. Maramelis, Proceedings of the First Symposium on Testing and Identification of Nonlinear Systems, California Institute of Technology, Pasadena 1975

[23] Neff, W.D., I.T. Diamond und J.H. Cassidy, Behavioral Studies of Auditory Discrimination: Central Nervous System, in [15], Teil 2, 3o7-4oo

[24] Parzen, E., Some Recent Advances in Time Series Modeling, IEEE Trans. Aut. Contr., 19, 723-73o, 1974

[25] Praetorius, H.M., Mustererkennung von stochastischen Signalen behandelt am Beispiel von bioelektrischen und geophysikalischen Aufzeichnungen, Dissertation, Univ. Göttingen 1976

[26] Rappelsberger, P., und H. Petsche, Spectral Analysis of the EEG by Means of Autoregression, in [7]

[27] Robinson, E.A., Predictive Decomposition of Time Series with Applications to Seismic Exploration, Geophysics, 32, 418-484, 1967

[28] Schroeder, M.R., Vocoders: Analysis and Synthesis of Speech, Proc. IEEE, 54, 72o-734, 1966

[29] Schroeder, M.R., Models of Hearing, Proc. IEEE, 63, 1332-1352 , 1975

[3o] Stark, L., Neurological Control Systems, Kap. 4: Functional Analysis of Pupil Nonlinearities, Plenum Press, New York 1968

[31] Ward, J.H., Hierarchical Grouping to Optimize an Objective Function, Amer. Statist. Assoc., 58, 236-244, 1963

[32] Watkins, S.L., Masked Three-Dimensional Plot Program With Rotations, Nr. 483 der "Collected Algorithms from CACM"

[33] Wiener, N., Extrapolation, Interpolation, and Smoothing of Stationary Time Series, Wiley, New York 1949

[34] Wiener, N., Nonlinear Problems in Random Theory, Wiley, New York 1958

Günter Bodenstein

Lebenslauf

9. Juni 1946	geboren in Lengerich/Westfalen
1952 - 1956	Grundschule
1956 - 1965	Ratsgymnasium Osnabrück, dort Abitur
SS 1965 bis SS 1967	Studium der Physik, später auch Mathematik, an der TU Clausthal
1967	Vordiplome in Mathematik und Physik
1967/1968	Studium in Applied Mathematics am Univ. of London King's College mit einem Stipendium der Studienstiftung des deutschen Volkes
SS 1968 bis SS 1971	Studium der Physik an der Universität Göttingen. Diplomarbeit in Quantenfeldtheorie bei Prof. Borchers.
1971	Diplom in Physik
1971/1972	Studium in Applied Physics and Information Science an der Univ. of California, San Diego Campus, mit einem Stipendium der Universität Göttingen
SS 1973 bis WS 1973	Studium am Fachbereich Kybernetik der TU Berlin
1973	Hospitant in der Abteilung für klinische Neurophysiologie des Klinikums Westend der FU Berlin bei Prof. Kubicki
SS 1974 bis SS 1976	Studium der Physik an der Universität Göttingen
1974 bis 1976	Anfertigung der Dissertation in der Abteilung Neurobiologie des Max-Planck-Instituts für biophysikalische Chemie in Göttingen bei Prof. Creutzfeldt.

An erster Stelle möchte ich Herrn Prof. Creutzfeldt danken, der das EEG-Projekt anregte, mir den Arbeitsplatz zur Verfügung stellte, und in zahlreichen Diskussionen zum Gelingen der Arbeit beitrug.

Herr Prof. Schroeder betreute die Arbeit von der physikalischen Seite und regte die Verwendung funktionaler Entwicklungen im zweiten Teil der Arbeit an.

Das EEG-Projekt, dessen methodisch-theoretischer Teil hier dargestellt ist, wurde gemeinsam mit H.M. Praetorius bearbeitet.

Meine erste Bekanntschaft mit dem EEG machte ich im Klinikum Westend, Berlin, in der Abteilung von Prof. Kubicki, wo M. Schoppenhorst mit der Prozeßrechnerverarbeitung befaßt war. H.J. Sack ist der im ersten Teil vielzitierte Neurologe.

Wesentlich für den Fortgang der Arbeit waren die häufigen anregenden und klärenden Diskussionen mit H.W. Strube; auch W. Möller sei hier erwähnt.

Die für den zweiten Teil der Arbeit erforderlichen Operationen an den Versuchstieren wurden freundlicherweise von M. Vollrath und Ch. Hellweg ausgeführt.

Schließlich danke ich allen Personen in verschiedenen Kliniken und Instituten für die Überlassung des verwendeten EEG-Materials.